



# IDRISI Selva

Guía para SIG y  
Procesamiento de Imágenes

Junio 2012  
J. Ronald Eastman

Manual Version 17

IDRISI Source Code  
© 1987-2012  
J. Ronald Eastman

IDRISI Production  
© 1987-2012  
Clark University



[www.clarklabs.org](http://www.clarklabs.org)  
[clarklabs@clarku.edu](mailto:clarklabs@clarku.edu)

# IDRISI Selva<sup>®</sup>

## Guía para SIG y Procesamiento de Imágenes<sup>®</sup>

Personal que contribuyó en la traducción al Español

Editor de la traducción:

**Dr. Andrés C. Ravelo**

Editores Asociados de la traducción:

**Ing. Agr. José A. Santa**

**Dr. Ernesto G. Abril**

**Dr. Raquel Gleiser**

**Dr. Mariano Grilli**

Traductora:

**Trad. Lorena Mosca**

Diseño gráfico:

**D. G. Alejandro Barbeito**

Nota: En caso de existir discrepancias entre las versiones en inglés y en español del Manual IDRISI, se considera como válido lo expresado en la versión en inglés.

Centro de Relevamiento y Evaluación de Recursos Agrícolas y Naturales (CREAN)

Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

Facultad de Ciencias Agropecuarias, Universidad Nacional de Córdoba

Ciudad de Córdoba, Argentina.

## Índice de Contenidos

<a href="#">Introducción a IDRISI Selva .....</a>	<a href="#">4</a>
<a href="#">Introducción a GIS .....</a>	<a href="#">9</a>
<a href="#">Introducción a los Sensores Remotos y al Procesamiento de Imágenes.....</a>	<a href="#">21</a>
<a href="#">Panorama General del Sistema IDRISI .....</a>	<a href="#">39</a>
<a href="#">Capas de Mapas, Archivos del Grupo Raster, Colecciones Vectoriales y Estructuras de Datos .....</a>	<a href="#">44</a>
<a href="#">Sistema de Visualización .....</a>	<a href="#">58</a>
<a href="#">Módulos de IDRISI .....</a>	<a href="#">77</a>
<a href="#">Taller para Bases de Datos.....</a>	<a href="#">97</a>
<a href="#">Cómo Realizar Consultas sobre Bases de Datos en IDRISI .....</a>	<a href="#">101</a>
<a href="#">Herramientas de Modelamiento del IDRISI .....</a>	<a href="#">103</a>
<a href="#">Desarrollo de las Bases de Datos.....</a>	<a href="#">110</a>
<a href="#">Georeferenciamiento.....</a>	<a href="#">119</a>
<a href="#">Apoyo en la Toma de Decisiones: Análisis de la Estrategia de Decisiones.....</a>	<a href="#">128</a>
<a href="#">Apoyo en la Toma de Decisiones: Manejo de la Incertidumbre.....</a>	<a href="#">147</a>
<a href="#">Restauración de Imágenes .....</a>	<a href="#">164</a>
<a href="#">Análisis de Fourier .....</a>	<a href="#">171</a>
<a href="#">Clasificación de las Imágenes de Sensores Remotos.....</a>	<a href="#">177</a>
<a href="#">Índices de Vegetación.....</a>	<a href="#">203</a>
<a href="#">Análisis e Imágenes RADAR.....</a>	<a href="#">217</a>
<a href="#">Análisis de Cambios .....</a>	<a href="#">220</a>
<a href="#">Modelador de Cambios en el Terreno para la Sustentabilidad Ecológica.....</a>	<a href="#">226</a>
<a href="#">Modelador de las Tendencias Terrestres.....</a>	<a href="#">248</a>
<a href="#">Análisis de Costos Anisotrópicos.....</a>	<a href="#">272</a>
<a href="#">Interpolación de Superficies.....</a>	<a href="#">277</a>
<a href="#">Generación de Superficies y Redes Irregulares Trianguladas.....</a>	<a href="#">283</a>
<a href="#">Geoestadística.....</a>	<a href="#">293</a>
<a href="#">Apéndice 1: Parámetros de los Elipsoides.....</a>	<a href="#">300</a>
<a href="#">Apéndice 2: Parámetros del Datum .....</a>	<a href="#">302</a>
<a href="#">Apéndice 3: Archivos de Parámetros Suministrados para el Sistema de Referencia.....</a>	<a href="#">311</a>
<a href="#">Apéndice 4: Fórmulas de Propagación de Errores.....</a>	<a href="#">321</a>

# CAPÍTULO 1 - Introducción a IDRISI Selva

## Contrato de licencia

El software descrito en este documento se encuentra bajo licencia y solamente debe ser usado y copiado de acuerdo con las condiciones de esta licencia.

El software IDRISI Selva descrito en este documento está protegido por la Ley del Derecho de Autor de Estados Unidos y por las provisiones del Tratado Internacional. Este software, es propiedad de Clark Labs, Universidad de Clark. Sin embargo, Clark Labs garantiza al comprador una licencia no exclusiva para usar el software sujeto a las disposiciones expuestas en esta declaración.

El comprador de una licencia de único usuario para IDRISI Selva está autorizado para instalar y usar el software en una computadora de un solo usuario y en ninguna otra. El comprador tiene permiso además para hacer una copia de seguridad de los medios de distribución de IDRISI Selva con el único propósito de proteger al comprador en caso de pérdida. El comprador no podrá alquilar o prestar el software, sin embargo, podrá transferir la licencia a otro usuario bajo acuerdo por escrito de Clark Labs. El usuario no podrá descomponer, descompilar o desarmar el software de IDRISI Selva ni ninguno de los programas relacionados incluidos en los medios de distribución.

Los manuales en formato pdf que acompañan este software también están protegidos por la Ley del Derecho de Autor de Estados Unidos y por las provisiones del Tratado Internacional. Se reservan todos los derechos. Ninguna parte de los manuales podrá ser reproducida, ni guardada en un sistema de búsqueda; o transmitida en ninguna forma o por ningún medio, ya sea electrónico, mecánico, por fotocopia, microfilm, registro u otros métodos, sin el permiso previo y por escrito de Clark Labs. La traducción directa de cualquier parte de los manuales también está prohibida sin el permiso escrito del titular.

## Garantía

Este software es vendido en las condiciones actuales, y la información en este manual está sujeta a cambios sin previo aviso. Aún más, Clark Labs no asume responsabilidad alguna por los errores que puedan aparecer en este documento o en el software que éste describe.

CLARK LABS DESAPRUEBA CUALQUIER OTRA GARANTÍA, EXPRESA O IMPLÍCITA, INCLUYENDO PERO NO LIMITÁNDOSE A LAS GARANTÍAS IMPLÍCITAS DE RENTABILIDAD Y APTITUD PARA UN PROPÓSITO EN PARTICULAR CON RESPECTO A LOS DEFECTOS EN EL CD-ROM Y/O DOCUMENTACIÓN, Y LA LICENCIA DEL PROGRAMA OTORGADA EN ESTE DOCUMENTO EN PARTICULAR, Y SIN LIMITAR EL FUNCIONAMIENTO DE LA LICENCIA DEL PROGRAMA CON RESPECTO A CUALQUIER APLICACIÓN, USO, O PROPÓSITO EN PARTICULAR. EN NINGÚN CASO, CLARK LABS SE HACE RESPONSABLE POR PÉRDIDAS DE GANANCIAS O NINGÚN OTRO DAÑO COMERCIAL, INCLUYENDO PERO NO LIMITÁNDOSE A DAÑOS ESPECIALES, INCIDENTALES, CONSECUENCIALES U OTROS.

## Marcas Registradas

IDRISI y CartaLinx son marcas registradas de Clark Labs, Universidad de Clark. Windows y Access son marcas registradas de Microsoft Corporation. ArcInfo y ArcView son marcas registradas del Instituto de Investigación en Sistemas Ambientales (Environmental Systems Research Institute), Inc. MapInfo es marca registrada de MapInfo Corporation. Acrobat Reader Copyright 1987-2003 Adobe Systems Incorporated. Se reservan todos los derechos. Adobe y su logotipo son marcas registradas de Adobe Systems Incorporated. Todos los demás nombres de productos mencionados en este volumen son marcas registradas de las empresas aquí mencionadas.

# Introducción

Gracias por elegir IDRISI Selva y bienvenido a Clark Labs.

IDRISI es la industria líder en funcionalidad analítica raster y cubre toda la gama de los requerimientos para SIG y sensores remotos desde incertidumbre sobre las bases de datos y modelación espacial hasta mejoramiento y clasificación de imágenes. Se incluyen utilidades especiales para el monitoreo ambiental y el manejo de recursos naturales, junto con análisis de cambio y series de tiempo, apoyo a las decisiones de criterios y objetivos múltiples, análisis de incertidumbre, modelos de simulación, interpolación de superficies y la caracterización de estadísticas. Sin embargo, a pesar de la naturaleza altamente sofisticada de estas utilidades, el sistema es de fácil manejo.

IDRISI consiste en un programa principal de interfase (incluyendo el menú y el sistema de barra de herramientas) y de una lista de 250 módulos de programa que proveen utilidades para la entrada, visualización y análisis de datos geográficos. Ver el capítulo de los Módulos de IDRISI para obtener un panorama general sobre la estructura del menú y una lista de todos los módulos y sus capacidades. Información detallada sobre cada módulo así como también una variedad de otros datos técnicos pueden hallarse en el Sistema de Ayuda on-line.

Junto con este manual, el paquete de software de IDRISI, también incluye un sistema de ejercicios de aprendizaje y los datos que dirigen al nuevo usuario con los conceptos de SIG y del proceso de imagen, también introduciendo las características de IDRISI. Los ejercicios de aprendizaje son apropiados para el autoentrenamiento o en la sala de clase.

## Acerca de Clark Labs

Clark Labs se dedica a la investigación y al desarrollo de tecnologías geoespaciales para la toma de decisiones efectivas y responsables relacionadas con el manejo del medio ambiente, el desarrollo de recursos sustentables y asignación equitativa de recursos.

Clark Labs es principalmente conocido por su producto líder, IDRISI SIG y el software de Procesamiento de Imágenes. Desde 1987, IDRISI ha sido utilizado por profesionales de una amplia variedad de industrias en más de 175 países en todo el mundo. Los administradores e investigadores del medio ambiente se benefician del inigualable alcance de herramientas geoespaciales, casi 300 módulos para el análisis y la visualización de información espacial digital.

Con su base en la mundialmente renombrada Escuela de Graduados de Geografía de la Universidad de Clark (Graduate School of Geography at Clark University), Clark Labs es conocido por sus pioneros avances en áreas tales como el apoyo de decisiones, manejo de la incertidumbre, desarrollo de clasificadores, análisis de cambio y series de tiempo y modelamiento dinámico. Asociado con organizaciones como la Fundación Gordon y Betty Moore, Google.org y USDA, Naciones Unidas y Conservación Internacional, Clark Labs se apoya en su base académica para desarrollar herramientas de investigación innovadoras y personalizadas, para brindar soluciones de software a organizaciones con dicha necesidad y para aplicar la experiencia geoespacial a un amplio rango de problemas reales del mundo.

## IDRISI no es una Acrónimo!

Un investigador musulmán, con reputación internacional en el mundo mediterráneo de esa época, Abu Abd Allah Muhammed al-Idrisi (1100-1166 A.C) nació en una ciudad ubicada sobre la costa Norte africana, probablemente la actual Ceuta. En aquel tiempo, esta zona era muy similar a Andalucía (sur de España) y al noroeste africano, parte del estado de Almoravid. Educado en la Universidad de Córdoba y realizó extensos viajes por Europa, el Norte de África, Medio Oriente y Asia Central. Al-Idrisi fue un cartógrafo y geógrafo de gran importancia durante la época medieval.

El rey Normando Roger de Sicilia le encargó la preparación de un estudio geográfico del mundo. Entonces, al-Idrisi condujo una investigación de quince años con la colaboración de investigadores y técnicos llevada a cabo en la Corte Normanda de Palermo. Basado en estudios directos de campo y en fuentes de archivos, los mapas y textos que resultaron de ese esfuerzo colaborativo sirvieron como material de referencia primaria durante más de 500 años. El software IDRISI está dedicado a este espíritu de colaboración en investigación geográfica.

# Explorando IDRISI

La mejor introducción a IDRISI es a través del **Tutorial**, al cual se puede acceder por medio del menú Ayuda (Help) del programa IDRISI. Además de trabajar con ejercicios, Ud. podrá leer el resto de **la Guía de IDRISI para SIG y el Procesamiento de Imágenes**.

Los tres primeros capítulos presentan un panorama general de IDRISI (este capítulo), del SIG y de los Sensores Remotos y el Procesamiento de Imágenes.

Los próximos capítulos exploran el uso del sistema IDRISI. El capítulo Panorama General del Sistema describe la naturaleza de la interface usuario. El capítulo Capas de Mapas, Archivos de Grupo Raster, Colecciones Vectoriales y Estructura de Datos destaca la lógica con la cual IDRISI organiza los datos, y da un resumen de las estructuras de los archivos de datos más comúnmente usados. El capítulo Sistemas de Visualización aborda los temas relacionados con la visualización de datos geográficos y las características de visualización interactiva disponibles para su exploración. El capítulo **Taller sobre Bases de Datos** describe el sistema de gestión de bases de datos y brinda información detallada sobre todas sus funciones, incluyendo la utilidad de unir una base de datos con un mapa y la utilidad para usar el lenguaje estructurado de consultas (SQL). El capítulo **Módulos de IDRISI** da un repaso de las capacidades de los módulos de IDRISI y su uso típico. Además, describe la lógica de la estructura del menú. El capítulo Herramientas de Modelación de IDRISI explica el uso del Macro Modelador, Calculadora de Imágenes, lenguaje macro de escritura y las herramientas modeladoras API (COM Server) de IDRISI. El capítulo **Desarrollo de las Bases de Datos** se ocupa de algunos de los temas importantes para el desarrollo y la creación de bases de datos SIG, en especial, técnicas para importar datos a IDRISI.

El capítulo **Georeferenciamiento** presenta temas de geodesia, datos geodésicos, proyecciones y sistemas de referencia con terminología entendible. Mientras muchas aplicaciones a nivel de proyecto del SIG y del procesamiento de imágenes no requieren georeferenciamiento para un sistema geodésico, la integración de datos con mapas gubernamentales locales o nacionales requerirá incuestionablemente la utilización de los temas tratados en este capítulo.

Los capítulos de **Apoyo a las Decisiones** serán de particular interés para aquéllos involucrados en la asignación y planeamiento de recursos. Éste cubre los procedimientos especiales requeridos para llevar a cabo análisis de criterios y objetivos múltiples así como también la toma de decisiones cuando existen dudas.

Muchos de los capítulos incluidos se refieren al uso de los datos de sensores remotos y a las técnicas de procesamiento de imágenes. El capítulo **Restauración de Imágenes** sugiere métodos para eliminar o disminuir el grado de distorsiones aleatorias y sistemáticas que ocurren en las imágenes. Un capítulo aparte sobre **Análisis Fourier** continúa con la discusión sobre los métodos para la remoción de ruidos. El capítulo **Clasificación de Imágenes de Sensores Remotos** se concentra en el enfoque de IDRISI en cuanto a la clasificación de imágenes, incluyendo el uso de los clasificadores “soft” (suaves) y “fuzzy” (difusos) para este proceso. Se discute también en este capítulo el uso de datos hiperespectrales. El capítulo **Análisis de Imágenes de RADAR** brinda algunas sugerencias para el uso de imágenes RADAR. El capítulo Índices de Vegetación describe los modelos de índices de vegetación incluidos en IDRISI para la transformación de imágenes satelitales en imágenes que indiquen la cantidad relativa de biomasa presente. El capítulo **Análisis de Cambio y Series de Tiempo** se ocupa de un juego de herramientas cada vez más importantes para el monitoreo ambiental. Los temas tratados incluyen comparaciones paralelas, procedimientos para distinguir los cambios reales de la variabilidad natural, perfiles temporales y análisis de series de tiempo por medio del Análisis de los Componentes Principales.

El capítulo Modelador de Cambios del Terreno presenta una discusión sobre las herramientas incluidas en el LCM para el análisis del cambio de cobertura del terreno, la proyección de su curso en el futuro, y la evaluación e implicaciones del cambio de hábitat y de la biodiversidad.

El capítulo moderador de las Tendencias Terrestres Terreno presenta una discusión sobre las herramientas incluidas dentro del ETM para el análisis de tendencias y las características dinámicas de éstos fenómenos como evidencia en las imágenes de series de tiempo.

Otro grupo de capítulos trata los temas del modelación de superficies con raster continuo. En el capítulo **Análisis del Costo Anisotrópico** se incluye una breve discusión de los procedimientos de distancia de costo del capítulo **Introducción al SIG** para considerar el caso de las fuerzas y fricciones anisotrópicas (por ejemplo, fuerzas y fricciones que actúan de manera diferente en direcciones diferentes). Estas herramientas son en cierta forma experimentales, pero ofrecen oportunidades especiales para el modelación de fenómenos dinámicos tales como las corrientes de aguas subterráneas, los movimientos del fuego en los bosques, derrames de petróleo, etc. Estos capítulos se focalizan en temas de la interpolación espacial de los datos de muestra.



El capítulo **Interpolación de la Superficie** da un panorama general de las técnicas que se encuentran comúnmente en el SIG y resalta algunas de sus ventajas y desventajas relativas. Además, indica como se llevan a cabo estas técnicas en IDRISI. El capítulo **Redes Triangulares Irregulares y Generación de Superficie** detalla la implementación del TIN en IDRISI. El capítulo **Geoestadísticas** presenta información para el uso de procedimientos geoestadísticos avanzados tales como el kriging y la simulación.

Este volumen además contiene una serie de Apéndices que incluyen parámetros para el Georeferenciamento y, de mayor importancia, tablas detalladas de las constantes usadas para la transformación entre datos de mapas y, también fórmulas de la propagación de errores tratadas en el capítulo **Apoyo a las Decisiones**.

El manual del Tutorial está pensado como un medio de aprendizaje (y enseñanza) del sistema IDRISI y de las herramientas básicas utilizadas en el SIG y en el procesamiento de imágenes. Los ejercicios se encuentran en un formato adecuado tanto para el uso en el aula como para la capacitación individual. Literalmente, miles de usuarios han aprendido los conceptos básicos del SIG por medio de estos ejercicios.

Además de los manuales descritos anteriormente, IDRISI también contiene un Sistema de Ayuda on-line muy completo. Éste no duplica la información de la **Guía de IDRISI**, sino que constituye un suplemento muy interesante. Específicamente, el Sistema de Ayuda contiene información detallada sobre el uso de cada módulo en IDRISI. Ésta incluye información sobre el funcionamiento, notas especiales, explicaciones de los mensajes de error, sintaxis de la línea de comandos, etc. Cada módulo posee un botón de ayuda (help) que se puede clicar para conseguir ayuda sobre ese módulo. El Sistema de Ayuda también puede accederse clicando el menú Help. Ud. encontrará allí una tabla de contenidos, un índice y una función de búsqueda de palabras clave. El Sistema de Ayuda también incluye un glosario básico e información detallada sobre el formato de archivos IDRISI.

## Cómo Contactar con Clark Labs

Esperamos que disfrute la utilización de IDRISI Selva. Invitamos a nuestros usuarios a brindarnos sus comentarios acerca de su experiencia con el sistema y sus métodos de aplicación.

Para contactar Clark Labs, nuestra dirección es:

Clark Labs. Clark University. 950 Main Street. Worcester, MA . 01610-1477 . USA.

Para contactarnos vía telefónica, fax, e-mail, o visitar nuestro sitio web:

Servicio al cliente: +1.508.793.7526 - Fax: +1.508.793.8842

Internet: <mailto:mclarklabs@clarku.edu>

Sitio web: <http://www.clarklabs.org/support/index.cfm>

Los horarios de nuestras oficinas son de 9 a 17 hs. Horario Este de EE.UU. (-5 hs. Invierno GMT/-4 hs. Verano GMT), de lunes a viernes. Los mensajes después de hora son receptados por un contestador automático.

## Política de Devoluciones de Clark Labs

Las devoluciones sólo se aceptan en casos en los que se presentan dificultades con la instalación, y deben recibir autorización previa del Servicio al Cliente.

## Soporte Técnico de Clark Labs

Clark Labs brinda soporte técnico de calidad a los usuarios registrados. Para aquellos que han contratado el soporte técnico, nosotros proveemos asistencia experta en los siguientes tipos de dificultades:

- Instalación del Software
- Asistencia en los Ejercicios de Aprendizaje
- Operación del Software
- Importación y Exportación de Formatos de datos Provistos.
- Identificación de Módulos Apropiados para Análisis Particulares

Para recibir asistencia técnica, Ud. necesita haber contratado el soporte técnico y tener la última versión de IDRISI o de CartaLinx. Brindamos actualizaciones de software gratuitas (conocidas como updates o patches) que cualquier usuario registrado puede bajar de nuestro sitio web: <http://www.clarklabs.org/support/index.cfm> Cliquee el número de su versión instalada en el menú Help/About (Ayuda/Acerca de) y luego visite el área de descargas de nuestro sitio web para comparar su número con el de la última actualización. Si la versión que Ud. posee tiene un número más bajo, descargue e instale la actualización. Luego de actualizar, fíjese que su problema haya sido resuelto.

Si Ud. tiene un problema técnico con un módulo específico o si Ud. obtiene resultados inesperados, la solución al problema puede encontrarse en el Sistema de Ayuda (Help System). Cliquee el Sistema de Ayuda para el módulo/comando que está utilizando. La mayoría de los comandos de IDRISI incluyen información suplementaria acerca de las limitaciones del módulo en la respectiva sección de Comentarios (Notes).

En caso de que ni la actualización ni el Sistema de Ayuda hayan resuelto su problema, contacte nuestro staff de Asistencia Técnica vía email a <mailto:mclarklabs@clarku.edu>. Para su conveniencia, nosotros ofrecemos formularios on-line en nuestra página de Asistencia Técnica. Estos formularios nos dan toda la información que necesitamos para resolver su problema tan rápido como sea posible.

En su primer contacto con nosotros, Ud. debe incluir la siguiente información:

- Número de identificación de cliente, nombre, teléfono y dirección de e-mail (si se posee)
- Nombre y número de versión del producto de Clark Labs que esta utilizando
- Descripción de su hardware y sistema operativo
- Descripción detallada de su problema. Debe incluirse una lista y una descripción de los juegos de datos involucrados, una descripción de la operación que intenta realizar y una descripción paso a paso de lo que Ud. ha realizado hasta ahora (con los valores específicos que haya ingresado en el cuadro de diálogo del módulo). Además debe incluir el texto exacto de todos los mensajes de error que reciba.

## El Staff de Clark Labs

A diciembre de 2011, el personal de Clark Labs incluía:

**Ananya Baruah** (India), Control de Calidad

**Aminatas Brandao Jr.**

**Laurie Canavan** (EE.UU), Director Asistente

**Hao Chen** (China), Miembro Adjunto Sénior de Investigación

**Dan Cheng** (China), Control de Calidad

**Christina Connolly** (EE.UU), Asistente de Atención al Cliente

**Stefano Crema** (Brasil), Miembro Adjunto de Investigación

**Nicholas Cuba** (EE.UU), Control de Calidad

**Ngoc Dinh** (Vietnam), Asistente Becario

**Ron Eastman** (Canadá), Director / Arquitecto Titular

**David Eitelberg** (EE.UU), Servicio Técnico

**Annalise Erkkinen** (EE.UU), Control de Calidad

**Bardan Ghimire** (Nepal), Asistente de Investigación

**Andrew Hostetler** (EE.UU), Control de Calidad

**Qi Qi Jiang** (China), Control de Calidad

**David Johnson** (EE.UU), Control de Calidad

**Cao Kang** (China), Asistente de Investigación

**Julia Lenhardt** (EE.UU), Control de Calidad

**Ivan Lucena** (Brasil) Programador SIG

**Elia Axinia Machado** (España), Asistente de Investigación

**Fei Meng** (China), Control de Calidad

**Nathan Mietkiewicz** (EE.UU), Servicio Técnico

**Neeti Neeti** (India), Asistente de Investigación

**Anders Olsen** (EE.UU), Control de Calidad

**Benoit Parmentier** (Bélgica), Asistente de Investigación

**Florencia Sangermano** (Argentina), Miembro Adjunto de Investigación

**Brenna Schwert** (EE.UU), Servicio Técnico

**Sabine Shrestha** (Nepal), Asistente Becario

**Kangping Si** (China), Asistente de Investigación

**Diane Sutter** (EE.UU), Gerente de Atención al Cliente

**James Toledano** (EE.UU), Director Ejecutivo

**Pete Wason** (EE.UU), Tecnología de la Información

**Qingling Wu** (China), Asistente de Investigación

**Aster Xiang** (China), Control de Calidad

**Boyd Zapatka** (EE.UU), Servicio Técnico

**Yujia Zhang** (China), Asistente de Investigación

**Yao Zhou** (China), Asistente de Investigación

**Honglei Zhu** (China), Miembro Adjunto Sénior de Investigación



# CAPÍTULO 2 - Introducción al SIG

Un Sistema de Información Geográfica (SIG) es un sistema asistido por computadora para la adquisición, almacenamiento, análisis y visualización de datos geográficos. Hoy, se encuentra disponible una gran variedad de herramientas software para asistir estas tareas. Sin embargo, estas herramientas pueden variar significativamente unas de otras, en parte debido a la forma en que representan y trabajan con los datos geográficos, pero además debido al énfasis relativo que le dan a estas operaciones. En este capítulo, estudiaremos estas diferencias como una forma de entender las características especiales del sistema IDRISI.

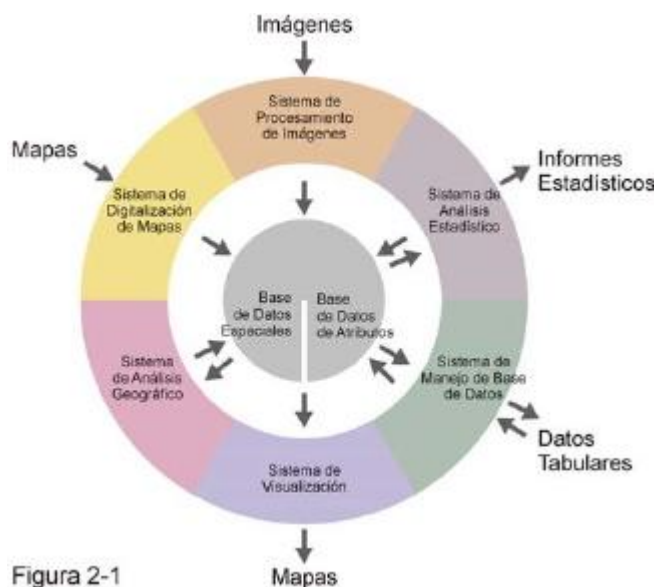
## Componentes del SIG

A pesar de que veamos el SIG como una sola pieza de software, éste generalmente está armado con una variedad de componentes diferentes. La Figura 2-1 presenta un amplio panorama de los componentes del software normalmente hallados en un SIG. No todos los sistemas tienen todos estos componentes; sin embargo, para que sea un verdadero SIG, debe poseer un grupo esencial de componentes.

## Bases de Datos Espaciales y de Atributos

La base de datos es central para el sistema: una colección de mapas e información relacionada en formato digital. Debido a que la base de datos se ocupa de las características de la superficie terrestre, puede interpretarse que consiste en dos elementos: una base de datos espaciales que describe la geografía (forma y posición) de las características de la superficie terrestre, y una base de datos de atributos que describe las peculiaridades o cualidades de estas características. Entonces, por ejemplo, se puede tener una parcela de propiedad definida en la base de datos espacial y cualidades como su uso de la tierra, dueño, valor de la propiedad, y demás, en la base de datos de atributos.

En algunos sistemas, las bases de datos espaciales y de atributos se distinguen claramente una de otra, mientras que en otros se encuentran íntimamente integradas en una sola unidad; la línea que se extiende sólo hasta la mitad del círculo en la Figura 2-1. IDRISI es de los sistemas que integran los dos componentes en uno. Sin embargo, también ofrece la opción de mantener algunos elementos de la base de datos de atributos lo suficientemente separados.



Esto se estudiará más adelante cuando examinemos las técnicas para la representación digital de datos de mapas.

## Sistema de Visualización Cartográfica

Existe una serie de componentes del software que rodean a la base de datos central. El componente más importante es el Sistema de Visualización Cartográfica. Este sistema permite tomar elementos seleccionados de la base de datos y proyectar mapas en la pantalla o en alguna forma sobre papel, como una impresión o plotter. La gama de las capacidades de producción cartográfica entre los software SIG es enorme. La mayoría sólo provee una producción cartográfica básica y depende del uso de sistemas software de publicación de alta calidad para las necesidades de producción más sofisticadas tales como la separación de colores.

IDRISI permite una composición cartográfica sobre la pantalla altamente interactiva y flexible, incluyendo la especificación de estratos múltiples de datos, personalización y posicionamiento de los elementos de mapas como anotaciones, barras de escala, proyecciones, textos o gráficos insertados, etc., y juegos de colores y símbolos personalizados. Las composiciones de mapas de IDRISI se pueden guardar para una visualización posterior. Además se las puede imprimir utilizando dispositivos compatibles con Windows y se pueden exportar en una variedad de formatos comunes de publicación por computadora.

Los sistemas software que sólo son capaces de acceder y visualizar los elementos de las bases de datos se los conoce a menudo como Viewers o Electronic Atlases (Atlas Electrónicos).

## **Sistema Digitalizador de Mapas**

Después de la visualización cartográfica, el próximo elemento en importancia es el Sistema Digitalizador de Mapas. Con un Sistema Digitalizador de Mapas, uno puede tomar mapas impresos en papel y convertirlos a formato digital y, como resultado, aumentar la base de datos. En el método más común de digitalización, el mapa se coloca sobre una tabla digitalizadora, luego se rastrean las características de interés con una púa, trazador o puntero, de acuerdo con los procedimientos requeridos por el software digitalizador. Muchos Sistemas Digitalizadores de Mapas permiten, además, editar los datos digitalizados.

El paquete del software CartaLinx, también desarrollado y distribuido por Clark Labs, brinda una capacidad digitalizadora y de edición vectorial completa, y es totalmente compatible con IDRISI. Además, existe un número de paquetes independientes de software digitalizadores compatibles con el formato de datos de IDRISI.

También se pueden usar scanners para digitalizar datos como fotografías aéreas. El resultado es más bien una imagen gráfica y no una producción de características como las creadas con una tabla digitalizadora. Los software de escaneo otorgan por lo general una variedad de archivos gráficos con formato estándar para su exportación. Estos archivos luego se importan en el SIG. IDRISI permite la importación de archivos gráficos con formato TIF y BMP.

Los paquetes digitalizadores, Computer Assisted Design (CAD) y Coordinate Geometry (COGO) son ejemplos de sistemas software que ofrecen la capacidad para agregar información digitalizada de mapas a la base de datos, y también capacidades de visualización cartográfica.

## **Sistema de Gestión de Bases de Datos**

El siguiente componente en un SIG es el Sistema de Gestión de Bases de Datos (DBMS). Tradicionalmente, este término se refiere al tipo de software que se utiliza para ingresar, manejar y analizar los datos de atributos. Aquí también se usa en ese sentido, pero debe reconocerse que además se requiere el manejo de los datos espaciales. Entonces, el SIG habitualmente incorpora no sólo DBMS sino también una variedad de utilidades para manejar los componentes espaciales y de atributos de los datos geográficos almacenados.

Con un DBMS, es posible ingresar datos de atributos tales como información tabular y estadísticas y, por consiguiente, extraer tabulaciones especializadas y resúmenes estadísticos para crear nuevos informes tabulares. Sin embargo, lo más importante del Sistema de Gestión de Bases de Datos es que éste nos brinda la capacidad para analizar datos de atributo. Muchos análisis de mapas no poseen componentes espaciales reales y por ello, un DBMS funcionará por lo general bastante bien. Por ejemplo, podremos usar el sistema para encontrar todas las parcelas de propiedad donde el casco de la casa sea unitario pero tenga una o más dependencias menores, y para confeccionar un mapa con los resultados. El producto final (un mapa) es ciertamente espacial, pero en el análisis en sí no posee ninguna cualidad espacial. Por lo tanto, las flechas dobles entre el DBMS y la base de datos de atributo en la Figura 2-1 representan esta forma no espacial de análisis de datos. En IDRISI, el Taller sobre Bases de Datos provee un DBMS. Uno puede realizar análisis en el Taller sobre Bases de Datos y luego aplicar inmediatamente los resultados a los datos espaciales adecuados y ver los resultados en forma de mapa. Además del este Taller, se encuentra disponible un extenso juego de módulos de programa para el manejo de los datos espaciales y de atributos.

Los software que brindan utilidades para la visualización cartográfica, digitalización de mapas y consultas sobre bases de datos se los llama a veces sistemas de Mapeo Automatizado y Gestión de Utilidades (Automated Mapping and Facilities Management - AM/FM) .

## **Sistema de Análisis Geográfico**

Hasta ahora, hemos descrito un juego de capacidades muy poderosas: la habilidad para digitalizar datos espaciales y agregar atributos a las características almacenadas, para analizar estos datos basados en dichos atributos, y para obtener los resultados en un mapa. Más aún, existe una variedad de sistemas en el mercado que poseen estas mismas habilidades, muchos de los cuales se llaman a sí mismos SIG. Sin embargo, a pesar de lo útil que éstos sean, sus capacidades no necesariamente constituyen un SIG completo. El componente faltante es la habilidad para analizar

datos, basada en características verdaderamente espaciales. Para esto, necesitamos un Sistema de Análisis Geográfico.

Con un Sistema de Análisis Geográfico, se extienden las capacidades de las consultas tradicionales sobre bases de datos para incluir la habilidad de analizar los datos desde su ubicación. Quizás el ejemplo más simple de esto sea considerar lo que ocurre cuando estamos interesados en la ocurrencia conjunta de características con diferentes geografías. Por ejemplo, supongamos que queremos hallar todas las áreas de terreno residencial sobre tipos de estratos rocosos asociadas con altos niveles de gas radón. Éste es un problema que un DBMS tradicional simplemente no puede resolver porque la roca del subsuelo y las divisiones del uso de la tierra no comparten la misma geografía. Las consultas tradicionales de las bases de datos son útiles siempre y cuando los atributos pertenezcan a las mismas características. Pero cuando las características son diferentes, éstas no sirven. Para esto necesitamos un SIG. En realidad, la habilidad para comparar características diferentes desde su ocurrencia geográfica común es el sello del SIG. Este análisis se cumple a través de un proceso llamado overlay (superposición). Lleva este nombre porque es lo mismo que superponer mapas transparentes de dos temas uno encima del otro.

Como el DBMS, el Sistema de Análisis Geográfico aparece en la Figura 2-1 con una interacción ida y vuelta con la base de datos; este proceso es distintivamente analítico en su naturaleza. Entonces, mientras ingresa información desde la base de datos, de la misma manera puede contribuir con los resultados de ese análisis como una nueva incorporación a la base de datos. Por ejemplo, podemos buscar la ocurrencia conjunta de terrenos sobre pendientes profundas con suelos erosionables para la agricultura y denominar el resultado un mapa de riesgo de erosión del suelo. Este mapa de riesgo no se encontraba en la base de datos original, sino que fue creado a partir de datos existentes y relaciones especificadas. Por lo tanto, las capacidades analíticas del Sistema de Análisis Geográfico y del DBMS juegan un papel vital en la extensión de la base de datos por medio de la incorporación de información sobre las relaciones entre características.

## **Sistema de Procesamiento de Imágenes**

Además de estos elementos esenciales de un SIG, un Sistema de Visualización Cartográfica, un Sistema de Digitalización de Mapas, un Sistema de Gestión de Bases de Datos y un Sistema de Análisis Geográfico, algunos software también incluyen la habilidad de analizar imágenes de sensores remotos y proveer análisis estadísticos especializados. IDRISI es de este tipo. Los software de procesamiento de imágenes permiten tomar imágenes de sensores remotos en vivo (tales como imágenes satelitales LANDSAT o SPOT) y convertirlas en datos de mapa, interpretados de acuerdo a varios procedimientos de clasificación. En reconocimiento a su gran importancia como técnica de adquisición de datos, IDRISI ofrece un amplio juego de herramientas para la interpretación asistida por computadora de datos obtenidos por medio de sensores remotos.

## **Sistema de Análisis Estadístico**

Para el análisis estadístico, IDRISI ofrece ambos procedimientos estadísticos tradicionales así como también algunas rutinas especializadas para el análisis estadístico de datos espaciales. Los geógrafos han desarrollado una serie de rutinas especializadas para la descripción estadística de datos espaciales, en parte debido al carácter especial de los datos espaciales, pero también debido a que los datos espaciales plantean problemas especiales para las inferencias extraídas de los procedimientos estadísticos.

## **Sistema de Apoyo a las Decisiones**

Mientras el apoyo a las decisiones es una de las funciones más importantes de un SIG, las herramientas diseñadas específicamente para esta función son relativamente pocas en la mayoría de los software SIG. Sin embargo, IDRISI incluye varios módulos particularmente desarrollados para asistir en los procesos de toma de decisiones con respecto a la asignación de recursos. Éste incluye módulos que incorporan errores al proceso, ayudan en la construcción de mapas de aptitud de criterios múltiples bajo niveles variantes de intercambio (tradeoff), y elaboran las decisiones de asignaciones cuando hay involucrados objetivos múltiples. Utilizados junto con los demás componentes del sistema, estos módulos brindan una herramienta poderosa para la toma de decisiones sobre la asignación de recursos.

## **Representación de los Datos Cartográficos**

La forma en que los componentes del software mencionados anteriormente logran combinarse, es un aspecto de la variación de los Sistemas de Información Geográfica. Sin embargo, una distinción fundamental es la manera en que éstos representan los datos cartográficos en formato digital.

Un Sistema de Información Geográfica almacena dos tipos de datos que se encuentran en los mapas: las definiciones geográficas de las características de la superficie terrestre y los atributos o cualidades que esas características poseen. No todos los sistemas usan la misma lógica para lograr esto. Casi todos, sin embargo, usan una o la combinación de ambas técnicas fundamentales de representación cartográfica: vectorial y raster.

## Vectorial

Con la representación vectorial, los límites o el curso de las características se definen por medio de una serie de puntos que, cuando se los une con líneas rectas, forman una representación gráfica de esa característica. Los puntos mismos están codificados en un par de números que forman las coordenadas X e Y en sistemas tales como la latitud/longitud o la grilla de coordenadas del Universal Transverse Mercator. Los atributos de las características son almacenados entonces con un software tradicional de gestión de bases de datos (DBMS). Por ejemplo, un mapa vectorial de parcelas de propiedad puede estar ligado a una base de datos de atributos con información que contiene la dirección, el nombre del dueño, el valor de la propiedad y el uso del suelo. El lazo entre estos dos archivos de datos puede ser un simple número de identificación que se le da a cada característica en el mapa (Figura 2-2).

## Raster

La segunda forma de representación más importante es conocida como raster. Con los sistemas raster, la representación geográfica de características y de los atributos que éstas poseen se mezclan en archivos de datos unificados. En realidad, por lo general no definimos las características. Más aún, el área de estudio se divide en una fina red de una grilla de celdas en las que guardamos la condición o atributo de la superficie terrestre en ese momento (Figura 2-2). A cada celda se le da un valor numérico, el cual luego representará un identificador de característica, un código de atributo cualitativo o bien un valor de atributo cuantitativo. Por ejemplo, una celda puede tener un valor “6” para indicar que pertenece al Distrito 6 (identificador de característica), que está cubierta por el tipo de suelo 6 (atributo cualitativo), o que está 6 metros sobre el nivel del mar (valor de atributo cuantitativo). A pesar de que los datos que almacenamos en esta grilla de celdas no necesariamente se refieren al fenómeno que se puede observar en el ambiente, las grillas de datos pueden interpretarse como imágenes o capas, cada una ilustrando un tipo de información sobre la región comprendida en el mapa. Esta información puede ser visible a través de un visualizador raster. En un visualizador raster, tal como la pantalla de su computadora, también hay una grilla con pequeñas celdas llamadas píxeles. La palabra pixel es una contracción del término picture element (elemento de la imagen). Los píxeles pueden variar en su color, forma o tono de gris. Para elaborar una imagen, los valores de las celdas en la grilla de datos se usan para regular directamente la apariencia gráfica de sus píxeles correspondientes. Entonces, en un sistema raster, los datos controlan directamente la forma visible que observamos.

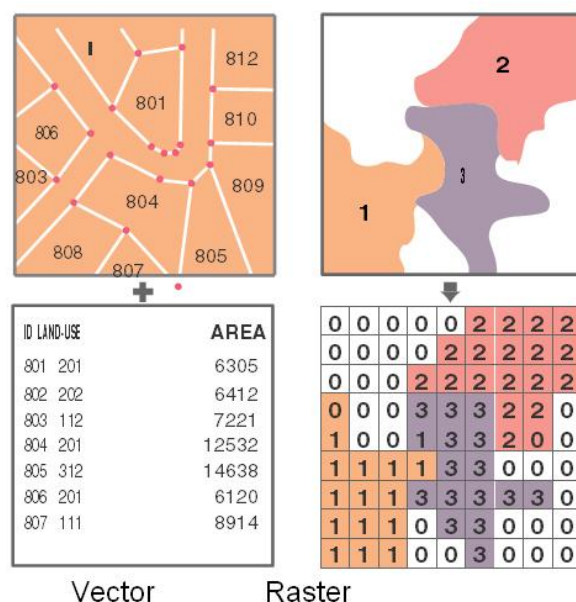
## Raster versus Vectorial

Los sistemas raster son por lo general de datos intensivos (aunque existan buenas técnicas para la compresión de datos) debido a que éstos deben guardar datos en cada ubicación de celda, sin importar si la información que tiene la celda es de interés o no. Sin embargo, la ventaja reside en que el espacio geográfico está uniformemente definido de manera simple y predecible. Como resultado, los sistemas raster tienen substancialmente más poder analítico que sus pares vectoriales en el análisis de espacio continuo<sup>1</sup> y son idealmente apropiados para el estudio de datos que están en constante cambio sobre el espacio como el terreno, la biomasa vegetal, las lluvias, etc. La segunda ventaja del raster consiste en que su estructura es bastante compatible con la arquitectura de las computadoras digitales. Como consecuencia, los sistemas raster tienden a ser muy rápidos en la evaluación de problemas que implican varias combinaciones matemáticas de los datos en capas múltiples. De este modo, son excelentes para evaluar modelos ambientales como el potencial de la erosión de suelos y la aptitud de manejo forestal. Además, debido a que las imágenes satelitales emplean una estructura raster, la mayoría de los sistemas raster pueden incorporar con facilidad estos datos, y algunos brindan completas capacidades de procesamiento de imágenes.

Mientras los sistemas raster están predominantemente orientados al análisis, los sistemas vectoriales tienden a estar más orientados a la gestión de las bases de datos. Los sistemas vectoriales son bastante eficientes en su almacenamiento de datos cartográficos porque sólo guardan los límites de las características, y no aquello que se encuentra dentro de esos límites. Debido a que la representación gráfica de las características está directamente ligada a la base de datos de atributos, los sistemas vectoriales generalmente permiten recorrer la visualización gráfica con un mouse y consultar los atributos asociados con las características visualizadas, tales como la distancia entre puntos o a lo largo de líneas, las áreas de las regiones definidas sobre la pantalla, etc. Por otra parte, pueden producir mapas temáticos simples de las consultas de las bases de datos como una que muestre todas las secciones de líneas de canales de más de un metro de diámetro instaladas antes de 1940.

---

<sup>1</sup> A la estructura básica de los datos de los sistemas vectoriales se la puede describir como una red. Entonces, no es novedoso encontrar que los sistemas vectoriales tienen capacidades excelentes para el análisis de redes de espacio. Por lo tanto, la diferencia entre un vector y un raster es más una diferencia en los tipos de espacios que se describen que una habilidad inherente a los sistemas.



**Figura 2-2**

Comparados con sus pares raster, los sistemas vectoriales no tienen una gama tan extensa de capacidades para los análisis de espacio continuo. Sin embargo, se destacan en los problemas concernientes a los movimientos sobre una red y pueden realizar las operaciones más fundamentales de un SIG que se detallarán a continuación.

Para muchos, las funciones simples de gestión de bases de datos y las excelentes capacidades para confeccionar mapas son las que hacen atractivos a los sistemas vectoriales. Debido a la cercana afinidad entre la lógica de la representación gráfica y la producción tradicional de mapas, los sistemas vectoriales son usados para producir mapas que son distinguibles de aquellos confeccionados con medios tradicionales; como resultado, los sistemas vectoriales son muy populares en aplicaciones municipales donde predominan ciertos temas de gestión de la producción de mapas y de bases de datos.

Los sistemas raster y vectoriales poseen cada uno sus fuertes espaciales. Entonces, IDRISI incorpora elementos de ambas técnicas de representación. Aunque sea principalmente un sistema analítico raster, IDRISI emplea estructuras de datos vectoriales como forma principal de visualización e intercambio de datos cartográficos. Además, también ofrece aspectos fundamentales de la gestión de bases de datos vectoriales.


## Conceptos de Bases de Datos Geográficos

### Organización

Si usamos una lógica raster o vectorial para la representación espacial, comenzamos a ver que una base de datos geográficos –una base de datos completa para una región dada– está organizada en una forma similar a una colección de mapas (Figura 2-3). Los sistemas vectoriales se aproximan más a esta lógica a la que conocemos como coverages (áreas de cobertura) – colecciones como las de mapas que contienen las definiciones geográficas de un grupo de características y sus respectivas tablas de atributos. Sin embargo, estas áreas de cobertura se diferencian de los mapas en dos puntos.

Primero, cada una por lo general contiene información sólo sobre un tipo de característica, como parcelas de propiedad, polígonos del suelo, etc. Segundo, éstas pueden contener una serie completa de atributos que corresponden a esas características como un juego de información de censo para bloques urbanos.

Los sistemas raster también utilizan esta lógica de estilo cartográfico, pero usualmente dividen los juegos de datos en capas (layers) unitarias. Una capa contiene todos los datos para un solo atributo. Entonces, uno puede tener una capa de suelo, una de caminos y otra del uso de la tierra. Unos pocos sistemas raster, incluyendo IDRISI, pueden unir una capa de identificación de características (una capa que contiene los identificadores de las características ubicadas en cada celda de la grilla) con tablas de atributos. Más comúnmente, existen capas separadas para cada atributo y de éstas se producen visualizaciones sobre la pantalla y mapas en papel, por separado o bien en combinación.



**Figura 2-3**

Aunque existen diferencias mínimas, para todas las intenciones y propósitos, las capas raster y las áreas de cobertura vectorial se pueden interpretar simplemente como manifestaciones diferentes de un mismo concepto – la organización de la base de datos en temas elementales del estilo de los mapas. Sin embargo, las capas y las áreas de cobertura se diferencian en gran medida de los tradicionales mapas en papel. Cuando los datos cartográficos están codificados en formato digital (digitalizados), las diferencias de escala son eliminadas. Los datos digitales pueden ser visualizados o impresos en cualquier escala. Más importante, las capas de datos digitales que fueron extraídas de mapas en papel de diferentes escalas, pero que cubren la misma área geográfica, pueden ser combinadas.

Además, muchos paquetes SIG, incluyendo IDRISI, brindan utilidades para cambiar la proyección y el sistema de referencia de las capas digitales. Esto permite convertir a las capas múltiples, digitalizadas a partir de mapas de varias proyecciones y sistemas de referencia, en un sistema común.

Con la habilidad para manejar diferencias de escala, de proyección y de sistema de referencia, las capas se pueden unir con facilidad, eliminando de esta forma un problema que tradicionalmente ha dificultado las actividades de planeamiento con mapas de papel. Es importante destacar, sin embargo, que el problema de la resolución (resolution) de la información en las capas de datos permanece. Aunque las características digitalizadas de un planisferio grande podrían combinarse en un SIG con características digitalizadas de un mapa local a gran escala como un mapa urbano de calles, esto normalmente no se realiza. El nivel de precisión y detalle de los datos digitales sólo puede ser tan bueno como el de los mapas originales.

## Georeferenciamiento

Todos los archivos de datos espaciales en un SIG están georeferenciados. El georeferenciamiento se refiere a la ubicación de una capa o área de cobertura en el espacio según las define un reconocido sistema de referenciamiento de coordenadas. Con las imágenes raster, una forma común de georeferenciamiento es indicar el sistema de referencia (Ej.: latitud / longitud), las unidades de referencia (Ej.: grados) y las posiciones de las coordenadas de los bordes izquierdo, derecho, superior e inferior de la imagen. Lo mismo ocurre con los archivos de datos vectoriales, aunque los bordes izquierdo, derecho, superior e inferior aquí se refieren a lo que comúnmente se llama bounding rectangle (rectángulo delimitante) del área de cobertura – un rectángulo que define los límites del área<sup>2</sup> incluida en el mapa. Esta información es particularmente importante en un SIG integrado como IDRISI, ya que permite a los archivos raster y vectoriales relacionarse entre sí en forma confiable y significativa. Es también vital para el referenciamiento de los valores de los datos en posiciones reales sobre el terreno.

<sup>2</sup> El rectángulo comprometido se define a través de la región de estudio de interés y no necesariamente se refiere a las coordenadas mínimas y máximas actuales en el archivo de datos.



El georeferenciamiento es una consideración extremadamente importante cuando se usa un SIG. Por lo tanto, este tema es tratado en detalle más adelante en un capítulo separado.

## **Análisis en SIG**

La organización de la base de datos en capas no se debe simplemente a razones de claridad organizativa, sino que sirve para proveer rápido acceso a los elementos de los datos requeridos para el análisis geográfico. Aún más, la *raison d'être* para un SIG es ofrecer un medio para el análisis geográfico.

Las características analíticas del SIG pueden ser abordadas desde dos perspectivas. Primero, uno puede ver las herramientas que ofrece el SIG. Luego uno puede ver los tipos de operación que el SIG permite realizar. Sin importar si estamos usando un sistema raster o vectorial, veremos que las herramientas se dividen en cuatro grupos y las operaciones realizadas se dividen en tres.

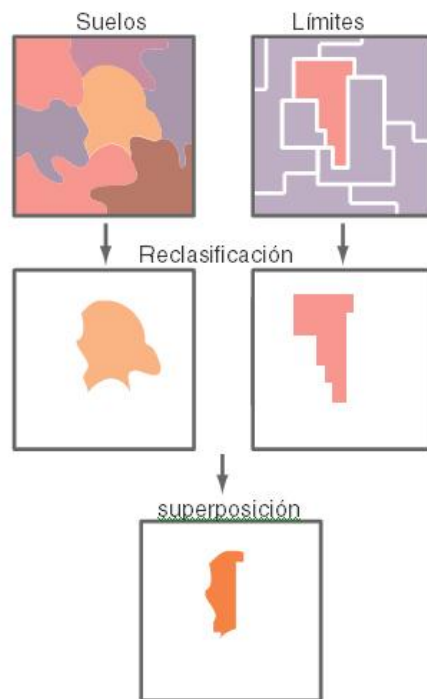
### **Herramientas Analíticas** **Consultas sobre la Base de Datos**

Las herramientas más importantes de todas las ofrecidas por un SIG son las relacionadas con la consulta sobre las bases de datos. La consulta sobre las bases de datos simplemente elabora preguntas acerca de la información actualmente almacenada. En algunos casos, preguntamos por lugar – ¿qué uso del suelo tiene el terreno en esta ubicación?. En otros, preguntamos por atributo – ¿qué áreas poseen un alto nivel de gas radón?. A veces elaboramos preguntas simples como las ilustradas anteriormente, y otras veces preguntamos acerca de combinaciones complejas de condiciones – mostrar todas las pantanos mayores de 1 hectárea y adyacentes a tierras industriales.

En la mayoría de los sistemas, incluyendo IDRISI, estas operaciones de consulta son llevadas a cabo en dos pasos. El primer paso, llamado reclasificación (*reclassification*), crea una nueva capa de cada condición individual de interés (Figura 2-4). Por ejemplo, considere una pregunta para encontrar áreas residenciales sobre roca de subsuelo relacionada con altos niveles de gas radón. El primer paso sería crear una capa con las áreas residenciales solas reclasificando todos los códigos de uso de la tierra en sólo dos. – un 1 cuando un área es residencial y un 0 para todos los demás casos.

La capa resultante es conocida como capa o máscara Booleana porque sólo muestra aquellas áreas que cumplen con la condición (1 = verdadero, residencial) y aquellas que no (0 = falso, no residenciales). Las capas Booleanas también son llamadas capas lógicas porque sólo muestran las relaciones verdadero / falso. A veces también se las llama capas binarias debido a que sólo contienen ceros y unos. Sin embargo, evitaremos usar ese término ya que también describe un tipo particular de formato de almacenamiento de datos. Aquí las llamaremos capas Booleanas.

Una vez que la capa residencial ha sido creada, también se reclasifica una capa geológica para crear una capa Booleana que muestre las áreas sobre roca de subsuelo relacionadas con altos niveles de gas radón. En este punto podemos combinar las dos condiciones usando una operación de superposición (*overlay*) (Figura 2-4). Como se dijo anteriormente, sólo un SIG es capaz de combinar condiciones tales como ésta, que implica características con distintas geografías. Por lo general, una operación de superposición en un SIG dará lugar a la producción de nuevas capas basadas en alguna combinación lógica o matemática de dos o más capas de entrada. En este caso de consulta sobre la base de datos, las operaciones lógicas claves son los operadores relacionales AND (Y) y OR (O), también conocidos como las operaciones de INTERSECCIÓN y de UNIÓN respectivamente. Aquí estamos buscando casos de terreno residencial AND gas radón alto – la intersección lógica de nuestras dos capas Booleana.



**Figura 2-4**

## Álgebra de Mapas

El segundo juego de herramientas que usualmente ofrece un SIG es para combinar las capas de los mapas matemáticamente. La modelación en particular requiere la habilidad para combinar capas de acuerdo a varias ecuaciones matemáticas. Por ejemplo, podemos tener una ecuación que predice la temperatura media anual como resultado de la altitud. O, como en otro ejemplo, podemos considerar la posibilidad de crear un mapa con el potencial de erosión del suelo basado en los factores de erosión del mismo, el grado de declive de la pendiente y la intensidad de las lluvias. Necesitamos claramente la habilidad para modificar los valores de los datos en nuestras capas de mapas por medio de varias operaciones y transformaciones matemáticas, y combinar matemáticamente los factores para producir un resultado final.

Las herramientas del Álgebra de Mapas ofrecen usualmente tres tipos diferentes de operaciones:

1. la habilidad para modificar matemáticamente los valores de los datos de atributo por medio de una constante (aritmética escalar);
2. la habilidad para transformar matemáticamente los valores de los datos de atributo por medio de una operación estándar (como las funciones trigonométricas, las transformaciones de registro, etc);
3. la habilidad para combinar matemáticamente (como sumar, restar, multiplicar, dividir) capas diferentes de datos para producir un resultado compuesto.

Esta tercera operación es simplemente otra forma de superposición de capas – la superposición matemática en contraposición a la superposición lógica de la consulta sobre la base de datos.

Para ilustrar esto, consideremos un modelo para el derretimiento de nieve áreas con bosques densos;<sup>3</sup>

$$M = (0.19T + 0.17D)$$

donde M es el índice de derretimiento en cm/día, T es la temperatura del aire y D, es la temperatura del punto de rocío. Dadas las capas con las temperaturas del aire y los puntos de rocío para una región de este tipo, podremos producir con claridad un mapa del índice de derretimiento de la nieve. Para realizar esto, se requerirá multiplicar la

<sup>3</sup>Ecuación tomada de Dunne, T., y Leopold, L.B., (1978) Water in Environmental Planning, (W.H. Freeman and Co.: San Francisco), p. 480.

capa de la temperatura por 0,19 (operación escalar), la capa con los puntos de rocío por 0,17 (otra operación escalar) y luego usar la superposición para sumar los dos resultados. A pesar de ser simple conceptualmente, esta habilidad para tratar las capas cartográficas como variables en fórmulas algebraicas es una capacidad enormemente poderosa.

## Operadores de Distancia

El tercer grupo de herramientas brindado por el SIG consiste en los Operadores de Distancia. Como el nombre lo indica, éstas son un juego de técnicas donde la distancia juega un rol clave en el análisis realizado. Virtualmente, todos los sistemas ofrecen las herramientas necesarias para construir zonas buffer o zonas de memoria intermedia auxiliar (circundantes) – áreas con una distancia específica de las características *target* (meta) designadas. Algunos también pueden evaluar la distancia desde todos los sitios hasta el juego de características designadas más cercano, mientras otros hasta pueden incorporar efectos y barreras de fricción en el cálculo de distancias (Figura 2-5).

Cuando se incorporan efectos de fricción, la distancia calculada es a menudo llamada distancia de costo (*cost distance*). Se usa este nombre porque el movimiento a través del espacio puede ocasionar costos, tanto en dinero como en tiempo y esfuerzo. Las fricciones aumentan esos costos. Cuando los costos de movimiento desde uno o más lugares se evalúan para una región entera, a menudo llamamos el resultado superficie de costo (*cost surface*) (Figura 2-5). En este caso, las áreas de bajo costo (supuestamente más cerca del punto inicial) se ven como valles y las de alto costo, como colinas. Una superficie de costo, entonces, tiene los puntos más bajos en los lugares iniciales, y los puntos más altos se encuentran en los lugares que están más lejos (en el sentido del mayor costo acumulado).<sup>4</sup>




Figura 2-5

Pueden haber casos en donde las fricciones no afectan el costo de movimiento de la misma manera en todas las direcciones. En otras palabras, éstas actúan *anisotrópicamente*. Por ejemplo, subir por una pendiente pronunciada puede ocasionar un costo mayor al ocasionado si se baja por la misma. Entonces, la dirección del movimiento por la fricción es importante, y debe tomarse en cuenta cuando se desarrolla la superficie de costo. IDRISI incluye módulos para modelar este tipo de superficie de costo, los cuales se explican en detalle en el capítulo Análisis de los Costos Anisotrópicos.

Dado el concepto de una superficie de costo, los Sistemas de Información Geográfica también ofrecen comúnmente *análisis de la ruta de menor costo* (least cost path analysis)— otra importante operación de distancia. Como el nombre lo indica, nuestra preocupación es evaluar la ruta de menor costo entre dos lugares. La superficie de costo ofrece la información necesaria para realizar esta evaluación (Figura 2-8).

Sin importar cómo es evaluada la distancia, ya sea por distancia de línea recta o de costo, otra herramienta comúnmente ofrecida es la *asignación* (allocation). Con esta, asignamos los lugares más cercanos al juego de características designadas.

Por ejemplo, podemos establecer un conjunto de instalaciones para la salud y luego asignar los residentes más cercanos a las instalaciones, donde “cercano” puede referirse a la distancia lineal o a una distancia de costo como el tiempo de viaje.

<sup>4</sup>Debe destacarse aquí que una superficie de costo como la descrita sólo puede ser evaluada con un sistema raster. Para los sistemas vectoriales, el equivalente más cercano serían las distancias de costo evaluadas sobre una red. Aquí observamos una simple, pero muy representativa, ilustración de las diferencias entre los sistemas raster y vectoriales con respecto a la manera de pensar el espacio.

## Operadores de Contexto

Finalmente, la mayoría de los Sistemas de Información Geográfica ofrece una variedad de Operadores de Contexto (también conocidos como operadores vecinos o locales). Con estos operadores, creamos nuevas capas basadas en la información de un mapa existente y en el contexto en el que éste se encuentra. Uno de los ejemplos más simples es el análisis de superficie donde usamos un modelo de elevación digital para producir una capa de pendientes por medio del examen comparativo entre las alturas de los lugares y las alturas de los lugares vecinos. De forma similar, el aspecto (la dirección hacia abajo de la pendiente máxima) también puede ser evaluado. Además, podemos posicionar una fuente de luz (light source) artificial y calcular un modelo de relieve sombreado. Estos productos de operadores de contexto y el modelo de elevación de donde fueron extraídos se ilustran en la Figura 2-6.




Figura 2-6

Un buen segundo ejemplo de un operador de contexto es un *filtro digital* (digital filter). Los filtros digitales operan cambiando los valores de acuerdo a las características de los valores vecinos. Por ejemplo, una superficie de terrenos altos puede ser alisada reemplazando los valores con el promedio de la altura original y de todas las alturas vecinas. Los filtros digitales tienen una amplia gama de aplicaciones en el SIG y en sensores remotos, que van desde la eliminación del ruido al mejoramiento visual de imágenes.

Debido a su simple y uniforme estructura de datos, los sistemas raster ofrecen una gran variedad de operadores de contexto. En IDRISI, por ejemplo, éstos incluyen análisis de superficie y filtro digital, identificación de áreas contiguas, análisis de cuencas, análisis de escenas (una evaluación de todas las áreas teniendo en cuenta uno o más detalles designados) y un procedimiento de modelación de oferta / demanda especial, donde las demandas se cubren al tomar las ofertas en forma radial desde los lugares vecinos.

## Operaciones Analíticas

Dadas las herramientas básicas, puede llevarse a cabo una amplia gama de operaciones analíticas. Sin embargo, puede parecer que la mayoría de estas operaciones están incluidas en uno de estos tres grupos básicos: Consultas sobre Bases de Datos, Confección de Mapas y Modelación de Procesos.

### Consultas sobre Bases de Datos

Con la Consulta sobre Bases de Datos, simplemente estamos seleccionando varias combinaciones de variables para examinar. Las herramientas que utilizamos son en gran medida las herramientas de Consultas sobre Bases de Datos discutidas anteriormente (de ahí el nombre), pero además incluyen varios procedimientos de análisis estadístico y de medición. La parte clave que distingue este tipo de análisis es que no extraemos más de lo que ingresamos al sistema. Mientras que podemos extraer combinaciones nunca antes examinadas, el sistema no nos brinda información nueva – simplemente estamos realizando una extracción desde un banco de datos que hemos construido.

Una de las actividades clave de una consulta sobre bases de datos es la búsqueda por patrón (pattern seeking). Normalmente buscamos patrones espaciales en los datos para que nos guíen, y poder así deducir las relaciones entre variables.

Con el mapeo derivativo, combinamos componentes seleccionados de nuestra base de datos para producir nuevas capas derivativas. Por ejemplo, podemos tomar nuestros datos de elevación digital para derivar el grado de inclinación de las pendientes, y luego tomar nuestra información de pendientes y combinarla con la información

sobre el tipo de suelo y el régimen de lluvias para producir un nuevo mapa del potencial de erosión del suelo. Entonces, este nuevo mapa se suma a nuestra creciente base de datos.

¿Cómo es posible crear nuevos datos de los antiguos? De forma diferente a la consulta sobre bases de datos donde simplemente extraemos información que ya se encuentra en la base de datos, con el mapeo derivativo, en cambio, tomamos información existente y le agregamos algo nuevo – *el conocimiento de las relaciones* entre los elementos de la base de datos. Podemos crear un mapa del potencial de la erosión del suelo usando una capa de elevación digital, una capa de los suelos y una capa del régimen de lluvias, sólo si conocemos la relación entre esos factores y el nuevo mapa que estamos creando. En algunos casos, estas relaciones se especificarán en términos lógicos (como crear un mapa de adaptabilidad para sitios industriales basado en la condición de que sea en tierras boscosas existentes, que se encuentre fuera de los *buffers* (límites) de protección alrededor de pantanos y que esté sobre pendientes bajas) y usaremos nuestras herramientas de consulta sobre bases de datos. En otros casos, sin embargo, estas relaciones se especificarán en términos matemáticos y dependerán en gran medida de las herramientas de Álgebra de Mapas. En ambos casos, deben conocerse las relaciones que forman el modelo.

En algunos casos, los modelos relacionales pueden ser derivados sobre fundamentos lógicos o teóricos. No obstante, muchas veces resulta necesario que las relaciones se determinen por estudios empíricos. El análisis regresivo, por ejemplo, es una forma muy común de prueba empírica utilizada para desarrollar una relación matemática entre las variables. Si uno toma el ejemplo de la erosión del suelo, uno puede establecer una serie de sitios de prueba en los que la erosión del suelo se mide junto con la pendiente, el tipo de suelo y los datos pluviales. Estos puntos de muestra se usarán luego para elaborar la ecuación que relacione la erosión del suelo con estas variables. La ecuación será usada entonces para evaluar el potencial de erosión del suelo sobre una región mucho más amplia.

## Modelación de Procesos

La consulta sobre bases de datos y el mapeo derivativo constituyen el volumen del análisis SIG realizado hasta ahora. Sin embargo, existe una tercera área que ofrece un potencial increíble – Modelación de Procesos o Simulación.

Con la modelación de procesos, también introducimos algo nuevo en la base de datos – conocimiento del proceso. El proceso se refiere a la cadena causal por la cual ocurren algunos eventos. Por ejemplo, un modelo simple de satisfacción de la demanda de combustible de madera puede realizarse de la siguiente manera:

1. Tomar toda la madera necesaria (si se puede) de la ubicación actual.
2. Si la demanda es cubierta o si se ha viajado más de 10 kilómetros desde el hogar, ir al paso 4.
3. Si la demanda no es cubierta, moverse a una ubicación inmediatamente adyacente no visitada anteriormente y repetir el paso 1.
4. Detenerse.

La modelación de procesos es un prospecto particularmente excitante para el SIG. Está basado en la noción de que en el SIG, nuestra base de datos no representa simplemente un medio ambiente, sino que *¡es un medio ambiente!* Es un ambiente suplente capaz de ser medido, manipulado y manejado por procesos geográficos y temporales. Entonces, nuestra base de datos actúa como un laboratorio para la exploración de procesos en un medio ambiente complejo. Tradicionalmente en la ciencia, hemos tenido que eliminar esa complejidad para poder entender los procesos por separado. Ésta ha sido una estrategia efectiva de la cual hemos aprendido mucho. Sin embargo, las tecnologías tales como los SIG ahora ofrecen las herramientas para re-ensamblar esas interpretaciones simples y obtener una comprensión y una apreciación sobre cómo actúan en la complejidad total de un ambiente real. A menudo, las interpretaciones muy simples producen patrones complejos cuando se les permite interactuar en el medio ambiente.

Un tipo diferente de proceso, el proceso de toma de decisiones, también puede ser asistido y en algunos casos modelado con la utilización de un SIG. La tecnología de los SIG se está volviendo más importante como herramienta para asistir la toma de decisiones. Es más, aún los resultados más simples de las consultas sobre bases de datos pueden ser inútiles para la toma de decisiones. Sin embargo, *el proceso* más complejo en la toma de decisiones, en el cual ésta a menudo se basa en términos de criterios múltiples, los límites suaves (no Booleanos) y los niveles de riesgo aceptables también pueden ser modelados con un SIG. IDRISI ofrece un juego de módulos para la asistencia en la toma de decisiones para ayudar a las personas encargadas de tomarlas a desarrollar decisiones más racionales y bien informadas. El capítulo Toma de Decisiones aborda en detalle el importante uso de los SIG y provee ejemplos de casos ilustrativos.

A pesar de su atracción evidente, la modelación de procesos, tanto en procesos ambientales como en la toma de decisiones, todavía es una actividad poco común en los SIG. La razón es bastante simple. Mientras cada vez más herramientas de modelación se encuentran disponibles en el SIG, es normal que el proceso de interés requiera una

capacidad no incluida en el sistema. Estos casos necesitan la creación de un nuevo módulo de programa. Muchos sistemas no están diseñados para la incorporación de rutinas desarrolladas por el usuario. IDRISI, en cambio, ha sido diseñado para que los programas hechos en cualquier lenguaje informático puedan compaginarse con el sistema y luego ser activados desde la interfase de IDRISI.

## La Filosofía del SIG

El SIG ha tenido un impacto enorme en casi todos los campos que manejan y analizan datos distribuidos espacialmente. Para aquellos que no están familiarizados con esta tecnología, es probable que lo vean como una caja mágica. La velocidad, consistencia y precisión con las que opera son verdaderamente impresionantes y lo mismo ocurre con su potente calidad gráfica. Sin embargo, para algunos analistas experimentados, la filosofía del SIG es bastante diferente. Con la experiencia, el SIG se convierte en una extensión del pensamiento analítico de uno mismo. El sistema no posee respuestas inherentes sino sólo aquellas del analista. Es una herramienta de la misma manera en que las estadísticas son una herramienta. Es una herramienta para el pensamiento.

Invertir en un SIG requiere más que una inversión en hardware y software. En realidad, muchas veces éste es el tema de menor preocupación. Muchos reconocen que una inversión sustancial debe ser realizada en el desarrollo de la base de datos. Sin embargo, una de las inversiones menos reconocida y sin embargo más importante está en los analistas que usarán el sistema. El sistema no puede ser separado de los analistas – uno es simplemente la extensión del otro. Además, el proceso de incorporación de las capacidades del SIG en una institución requiere una inversión a largo plazo y ampliamente organizada en educación y capacitación.

De muchas maneras, el aprendizaje del SIG implica aprender a pensar – aprender a pensar acerca de los patrones, del espacio y de procesos que actúan en el espacio. Mientras uno aprende sobre procedimientos específicos, éstos a menudo serán encontrados en el contexto de ejemplos específicos. Además, generalmente poseen nombres que sugieren su aplicación típica. Sin embargo, debe resistirse la tentación de categorizar estas rutinas. La mayoría de los procedimientos tienen muchas más aplicaciones generales y pueden usarse en varias formas innovadoras. ¡Explore! ¡Desafíe lo que ve! Lo que Ud. aprenderá va mucho más allá de lo que éste o cualquier otro paquete de software le puede ofrecer.



# CAPÍTULO 3 - Introducción a los Sensores Remotos y al Procesamiento de Imágenes

De todas las fuentes de información usadas en el SIG, una de las más importantes es sin dudas la de los sensores remotos, también llamada percepción remota o teledetección. A través del uso de satélites, ahora tenemos un programa continuo de adquisición de datos para el mundo entero con un marco de tiempo que va desde un par de semanas hasta algunas horas. Ahora también tenemos acceso a imágenes de sensores remotos en formato digital, las cuales permiten una integración rápida de los resultados del análisis de sensores remotos al SIG.

El desarrollo de técnicas digitales para la restauración, mejoramiento e interpretación asistida por computadora de imágenes de sensores remotos inicialmente procedía independientemente y de alguna manera con anterioridad al SIG. Sin embargo, la estructura raster de datos y muchos de los procedimientos involucrados en los *Sistemas de Procesamiento de Imágenes* (SPI) eran idénticos a los implicados en los SIG con sistema raster. Como resultado, es común ver que los paquetes software SPI agreguen capacidades generales para SIG, y los sistemas software SIG agreguen por lo menos un grupo fundamental de herramientas SPI. IDRISI es un sistema combinado de SIG y procesamiento de imágenes que ofrece capacidades avanzadas en ambas áreas.

Debido a la importancia extrema de los sensores remotos como una entrada de datos en el SIG, se ha vuelto necesario para los analistas del SIG (particularmente aquellos interesados en la aplicación de recursos naturales) familiarizarse en gran medida con los SPI. En consecuencia, este capítulo da un resumen de esta importante tecnología y su integración al SIG. Los ejercicios de Procesamiento de Imágenes en el **Tutorial** ilustran muchos de los conceptos presentados aquí.

## Definición

La percepción remota puede ser definida como cualquier proceso por el cual se reúne información acerca de un objeto, área o fenómeno, sin estar en contacto con éstos. Nuestros ojos son un ejemplo excelente de un dispositivo de percepción remota. Somos capaces de reunir información de nuestros alrededores evaluando la cantidad y naturaleza del reflejo de la energía de la luz visible proveniente de alguna fuente externa (como el sol o un foco) ya que ésta refleja los objetos comprendidos en nuestro campo visual. Contrasta esto con un termómetro, el cual debe estar en contacto con el fenómeno que está midiendo, por lo tanto no es un dispositivo de percepción remota.

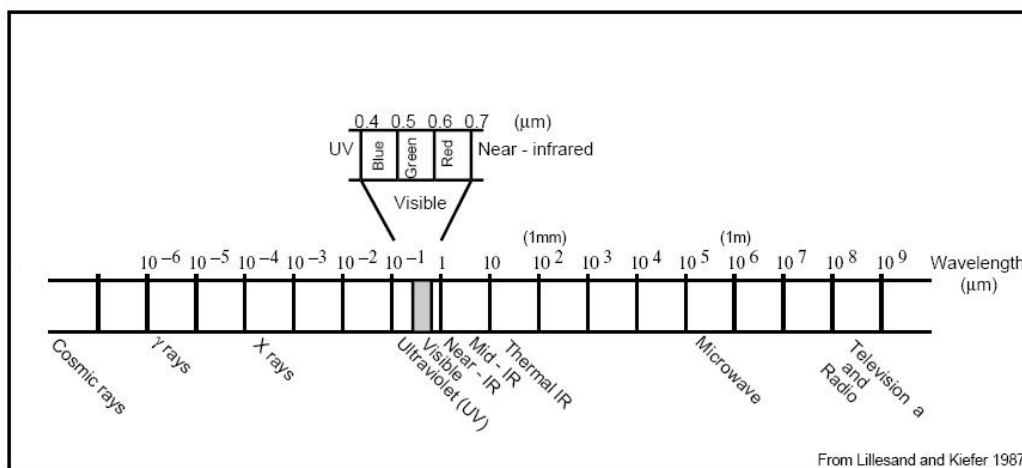
Dada esta definición bastante general, el término *percepción remota* es asociado más específicamente con la evaluación de las interacciones entre los materiales de la superficie de la tierra y la energía electromagnética. Sin embargo, cualquier intento semejante de una definición más específica se torna difícil ya que no siempre es el ambiente natural el que resulta captado por el sensor (Ej.: aplicaciones de conservación artística), el tipo de energía no es siempre electromagnética (Ej.: sonar) y algunos procedimientos evalúan emisiones de energía natural (Ej.: rayos infrarrojos termales) más que interacciones con la energía de una fuente independiente.

## Consideraciones Fundamentales

### Fuente de Energía

Los sensores pueden dividirse en dos grandes grupos – *pasivos* y *activos*. Los sensores pasivos miden los niveles ambientales de las fuentes de energía existentes, mientras que los activos poseen su propia fuente de energía. La mayoría de las actividades de los sensores remotos se realizan con sensores pasivos, para los cuales el sol resulta la mayor fuente de energía. El ejemplo más antiguo de esto es la fotografía. Con cámaras de transmisión aérea podemos desde hace tiempo medir y grabar el reflejo de la luz sobre los objetos de la tierra. Mientras la fotografía aérea es aún una forma importante de percepción remota, nuevas tecnologías de estado sólido han extendido las capacidades para ver las ondas visibles y las ondas de infrarrojo cercano (near infrared) e incluir también la radiación solar con ondas más largas. Sin embargo, no todos los sensores pasivos usan la energía del sol. Tanto los sensores de rayos infrarrojos termales (Termal IR) como los de microondas (microwaves) pasivos, miden las emisiones naturales de energía de la tierra. Entonces, los sensores pasivos son simplemente los que no suministran por sí solos la energía detectada.

En contraste, los sensores activos proveen su propia fuente de energía. La forma más familiar de esto es la fotografía con flash (destello). Sin embargo, en aplicaciones ambientales y cartográficas, el mejor ejemplo es el RADAR. Los sistemas RADAR emiten energía en la región de la microonda del espectro electromagnético (Figura 3-1). El reflejo de esa energía a través de materiales sobre la superficie de la tierra luego se mide para producir una imagen del área captada.



**Figura 3-1. El Espectro Electromagnético**

## Longitud de Onda

Como se indica, la mayoría de los dispositivos de percepción remota utilizan energía electromagnética. Sin embargo, el espectro electromagnético es muy amplio y no todas las longitudes de onda (wavelengths) son igualmente efectivas para ser usadas por los sensores remotos. Más aún, no todas tienen interacciones significativas con materiales de nuestro interés de la superficie terrestre. La Figura 3-1 ilustra el espectro electromagnético. La misma atmósfera causa una absorción y/o difusión significativa de las longitudes de onda más cortas. Además, las lentes de muchos sensores también causan una absorción importante de las longitudes de onda más cortas como los rayos ultravioletas (UV). Como resultado, la primera ventana de importancia (una región en la cual la energía puede pasar en gran medida a través de la atmósfera) se abre en las longitudes de onda visibles. Aún aquí, las longitudes de onda azules sufren una atenuación sustancial debido a la difusión atmosférica y, entonces, a menudo quedan fuera de las imágenes de sensores remotos. Sin embargo, todas las longitudes de ondas verdes, rojas y de infrarrojo cercano (IR) brindan buenas oportunidades para medir las interacciones de la superficie de la tierra sin interferencia considerable por parte de la atmósfera. Además, estas regiones proveen pistas importantes sobre la naturaleza de muchos materiales de la superficie terrestre. La clorofila, por ejemplo, es un absorbente muy potente de longitudes de onda rojas visibles, mientras que las longitudes de onda del infrarrojo cercano brindan importantes pistas sobre la estructura de las hojas de las plantas. Como resultado, el conjunto de imágenes de sensores remotos usado en aplicaciones relacionadas con el SIG es tomado en estas regiones.

Extendiéndonos hacia las regiones infrarrojas medias y termal, puede encontrarse una variedad de ventanas interesantes. Se ha comprobado que las longitudes de ondas infrarrojas más largas son útiles en un gran número de aplicaciones geológicas. Por otra parte, se ha comprobado que las regiones termal son útiles no sólo para el monitoreo de los casos obvios de distribución espacial del calor desprendido de la actividad industrial, sino también para un amplio grupo de aplicaciones que van desde el monitoreo del fuego y estudios sobre la distribución de animales hasta las condiciones de humedad del suelo.

Luego del IR termal, la siguiente área de mayor importancia en sensores remotos ambientales es la región de las microondas. Un número importante de ventanas existe en esta región. Éstas tienen una importancia particular para el uso de las imágenes activas de radar. La textura de los materiales de la superficie terrestre causa importantes interacciones con varias de las regiones de las microondas. Esto puede entonces ser usado como un suplemento para la información obtenida de otras longitudes de onda, y además ofrece la ventaja significativa de poder usarse de noche (porque como es un sistema activo, es independiente de la radiación solar) y en regiones de nubosidad persistente (ya que las longitudes de onda radar no son afectadas de manera significativa por las nubes).

## Mecanismos de Interacción

Cuando la energía electromagnética impacta el material, tres tipos de interacción pueden suceder: reflexión (reflection), absorción (absorption) y/o transmisión (transmission) (Figura 3-2). Nuestra mayor preocupación es con la porción reflejada ya que usualmente es ésta la que se envía de vuelta al sistema del sensor. La cantidad exacta reflejada variará y dependerá de la naturaleza del material y del lugar en el espectro electromagnético de donde se esté tomando la medida. Como resultado, si observamos la naturaleza de este componente reflejado sobre un rango de longitudes de onda, podemos caracterizar el resultado como un *patrón de respuesta espectral* (spectral response pattern).




Figura 3-2

### Patrones de Respuesta Espectral

Un patrón de respuesta espectral a menudo es llamado *firma o patrón* (signature). Es una descripción (a veces con forma de gráfico) del grado con el cual la energía es reflejada en las diferentes regiones del espectro. La mayoría de las personas están familiarizadas con los patrones de respuesta espectral ya que son equivalentes al concepto humano del color. Por ejemplo, la Figura 3-3 muestra patrones de respuesta espectral idealizados para varios colores familiares en la porción visible del espectro electromagnético, así como también para el blanco (white) y el gris oscuro (dark gray). El patrón de reflexión del rojo brillante (bright red), por ejemplo, puede ser aquél producido por un trozo de papel impreso con una tinta roja. Aquí, la tinta está diseñada para alterar la luz blanca que brilla sobre ésta y absorber las longitudes de onda azul y verde. Lo que queda entonces, son las longitudes de onda roja que reflejan la superficie del papel en sentido contrario hacia el sistema del sensor (el ojo). La alta devolución de longitudes de onda roja indican un rojo brillante, mientras que la baja devolución de longitudes de onda verde (green) en el segundo ejemplo, sugieren que el color aparecerá bastante oscuro.

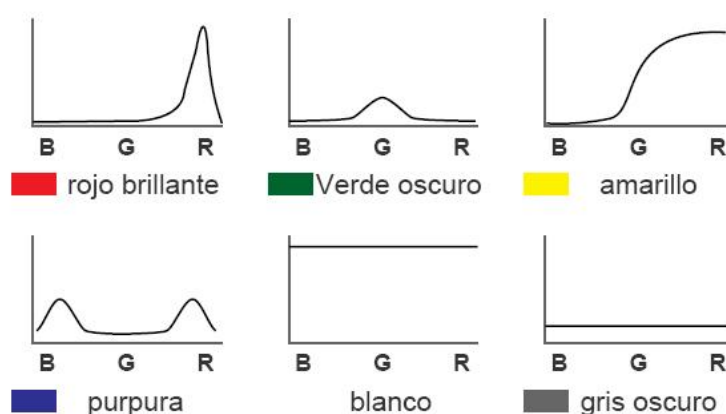


Figura 3-3

El ojo es capaz de captar patrones de respuesta espectral porque es un verdadero sensor multiespectral (capta más de un lugar en el espectro). Aunque el funcionamiento real del ojo es bastante complejo, tiene en realidad tres tipos separados de detectores que pueden interpretarse como si respondiesen a las regiones de longitud de onda roja, verde y azul. Éstos son los *colores primarios aditivos*, y el ojo responde a las combinaciones de estos tres para producir

una sensación de otros matices. Por ejemplo, el color percibido por el tercer patrón de respuesta espectral en la Figura 3-3 sería un amarillo (yellow) – el resultado de mezclar un rojo y un verde. Sin embargo, es importante reconocer que esto es sólo nuestra percepción fenomenológica del patrón de respuesta espectral. Considere, por ejemplo, la cuarta curva. Aquí tenemos reflejo en las regiones azul y verde del espectro visible. Ésta es una distribución bimodal, y por lo tanto, técnicamente no es un matiz específico en el espectro. Sin embargo, percibiríamos este matiz como morado (purple). El morado (un color entre el violeta y el rojo) no existe en la naturaleza (como un matiz – longitud de onda dominante y distintiva), aunque sea muy real en nuestra percepción. El morado es simplemente nuestra percepción de un patrón bimodal que involucra un par no adyacente de matices primarios.

En los primeros tiempos de la percepción remota, se creía (o, mejor dicho, se *esperaba*) que cada material de la superficie terrestre tuviera un patrón de respuesta espectral distinto que permitiera ser detectado de manera confiable por medios visuales o digitales. Sin embargo, como sugiere nuestra experiencia común con los colores, en realidad éste no es el caso. Por ejemplo, dos especies de árboles pueden tener una coloración bastante diferente en una época del año y una bastante similar en otra.

Encontrar patrones de respuesta espectral distintos es clave para la mayoría de los procedimientos de interpretación asistida por computadora de imágenes de sensores remotos. Esta tarea rara vez resulta trivial. Al contrario, el analista debe encontrar la combinación de bandas espectrales y la época del año en la cual se pueden hallar distintos patrones para cada una de las clases de información de interés.

Por ejemplo, la Figura 3-4 muestra un patrón de respuesta espectral idealizado para la vegetación, junto con aquellos patrones de agua y de suelos secos despejados. La fuerte absorción realizada por los pigmentos de las hojas (particularmente la clorofila para la fotosíntesis) en las regiones azules y rojas de la porción visible del espectro obedece a la típica apariencia verde de la vegetación sana. Aún así, mientras esta firma es distintivamente diferente de la mayoría de las superficies sin vegetación, no es muy capaz de distinguir entre distintas especies de vegetación – la mayoría posee un color verde similar cuando alcanzan la maduración completa. En las ondas del infrarrojo cercano, en cambio, encontramos una devolución mucho mayor de las superficies de vegetación debido a la difusión dentro de la carnosa capa mesofílica de las hojas. Los pigmentos vegetales no absorben energía en esta región, por lo tanto la difusión, combinada con el efecto multiplicador de un tapiz lleno de hojas, conduce a un reflejo alto en esta región del espectro.

Sin embargo, el alcance de este reflejo dependerá en gran medida de la estructura interna de las hojas (Ej.: hoja ancha versus hoja aguja). Como resultado, a menudo se pueden detectar en esta región diferencias significativas entre las especies. De manera similar, al movernos hacia la mitad de la región infrarroja, observamos una baja significativa en el patrón de respuesta espectral asociada con la humedad de las hojas. Esto es, una vez más, un área donde se pueden dar diferencias importantes entre las especies maduras. Por lo tanto, las aplicaciones que buscan una óptima diferenciación entre las especies usualmente incluyen las regiones de infrarrojo cercano e infrarrojo medio y utilizan imágenes tomadas dentro del ciclo de desarrollo.

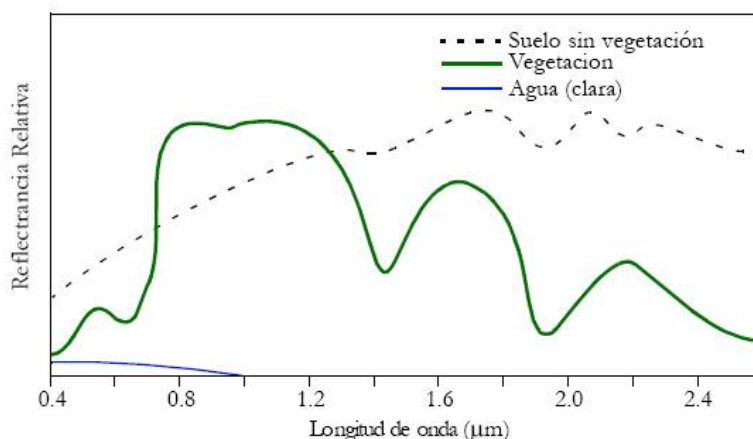


Figura 3-4. Adaptado de Lillesand and Kiefer 1987.

## Sensores Remotos Multiespectrales

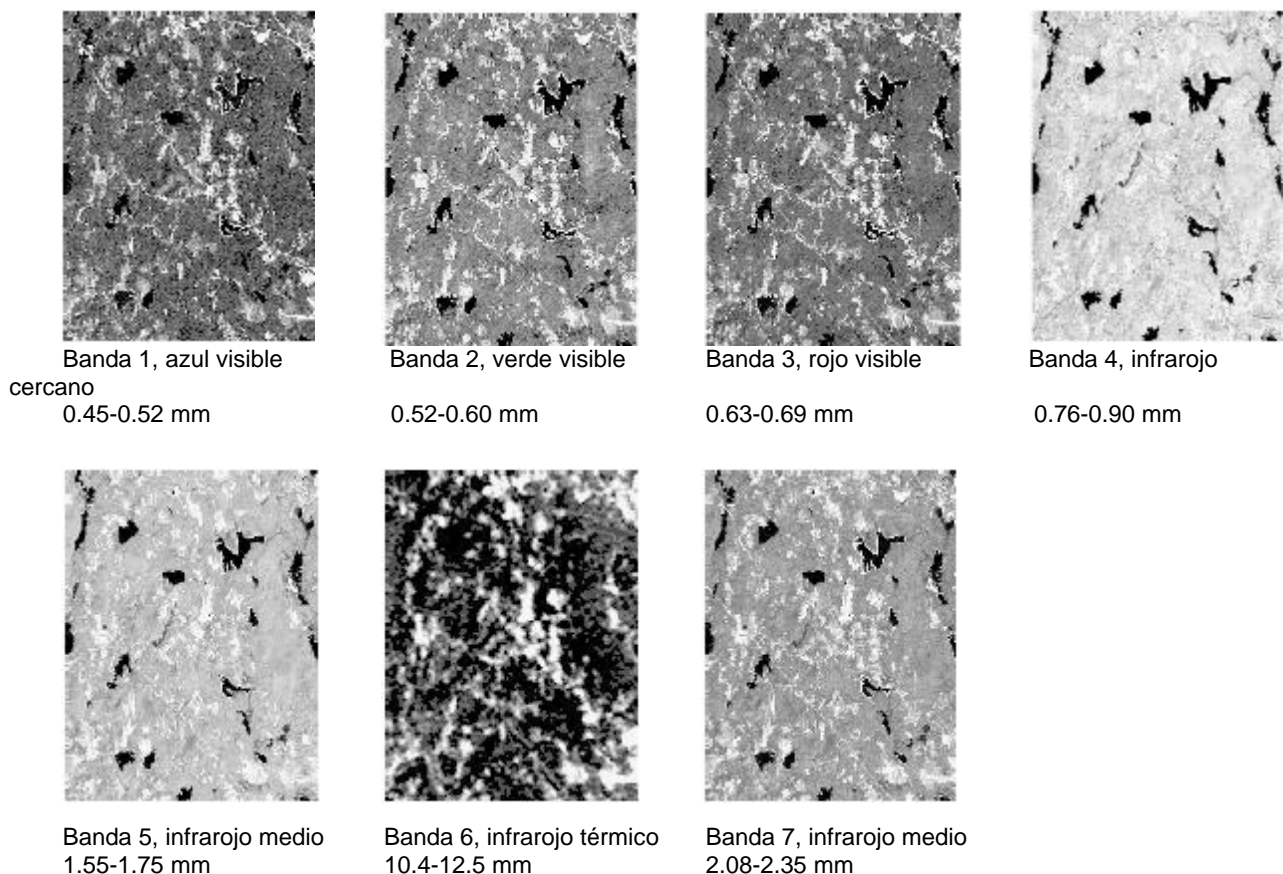
En la interpretación visual de imágenes de sensores remotos, se toma en consideración una variedad de características de las imágenes: color (o tono, en el caso de imágenes pancromáticas), textura, tamaño, forma, patrón, contexto, etc. Sin embargo, con la interpretación asistida por computadora, mayormente sólo se usa el color

(o sea, el patrón de respuesta espectral). Por esta razón, se pone gran énfasis en el uso de sensores multispectrales (sensores que, al igual que el ojo, captan más de un lugar en el espectro y, entonces, son capaces de medir los patrones de respuesta espectral), y en el número y la ubicación especial de estas *bandas* espectrales.

La Figura 3-5 ilustra las bandas espectrales del sistema LANDSAT Thematic Mapper (TM) (Cartografía Temática). El satélite LANDSAT es un sistema comercial que brinda imágenes multispectrales en siete bandas espectrales con una resolución de 30 metros.

A través de técnicas analíticas, como el Análisis de Componentes Principales, Se puede mostrar que, en muchos ambientes, las bandas que llevan la mayor cantidad de información acerca del medio ambiente natural son las bandas con longitud de onda del infrarrojo cercano y del rojo. El agua es absorbida en gran medida por las ondas infrarrojas y, por consiguiente, es altamente distintiva en esa región. Además, las especies vegetales usualmente muestran su mayor diferencia aquí. El área del rojo es también muy importante ya que es la región primaria en la cual la clorofila absorbe energía para la fotosíntesis. Entonces, es esta banda la que mejor puede distinguir entre superficies con y sin vegetación.

Dada la importancia de las bandas del rojo y del infrarrojo cercano, no es sorprendente que los sistemas diseñados para el monitoreo de recursos terrestres incluirán estas bandas en cualquier sistema multispectral en particular. Otras bandas dependerán del rango de aplicaciones previsto. Muchas incluyen la banda verde visible ya que ésta puede usarse, junto con las otras dos, para producir un tradicional compuesto de falso color – una imagen color derivada del verde, rojo y de las bandas infrarrojas (en contraposición al azul, verde y las bandas rojas de las imágenes con colores naturales). Este formato se hizo común con el advenimiento de la fotografía infrarroja color, y es familiar a muchos especialistas dedicados al campo de la percepción remota. Además, la combinación de estas tres bandas trabaja bien tanto en la interpretación del paisaje cultural como en las superficies naturales y con vegetación. Sin embargo, es cada vez más común incluir otras bandas que están más específicamente dirigidas a la diferenciación de los materiales de la superficie.



Por ejemplo, la Banda 5 del LANDSAT TM se coloca entre dos bandas de absorción de agua. Esto ha resultado muy útil para determinar diferencias en la humedad de los suelos y las hojas. De manera similar, la Banda 7 del LANDSAT TM apunta a la detección de zonas de alteración hidrotermal en superficies de roca pura. En contraste, el

sistema AVHRR de la serie de satélites NOAA incluye varios canales termales para la detección de las características de temperatura de las nubes.

## **Sensores Remotos Hiperespectrales**

Además de la tradicional imagen multiespectral, algunos sistemas nuevos y experimentales tales como AVIRIS y MODIS son capaces de capturar información *hiperespectral*. Estos sistemas cubren un rango de longitudes de onda similar a la de los sistemas multiespectrales, pero en bandas mucho más delgadas. Esto aumenta en gran medida el número de bandas (y por lo tanto la precisión) disponibles para la clasificación de imágenes (usualmente decenas y hasta centenas de bandas muy delgadas). Más aún, se han creado bibliotecas de patrones o firmas hiperespectrales en condiciones de laboratorio que contienen cientos de firmas para diferentes tipos de cubiertas terrestres, incluyendo muchos minerales y otros materiales terrestres. Entonces, debería ser posible unir firmas con los materiales de la superficie con gran precisión. Sin embargo, las condiciones del medio ambiente y las variaciones en los materiales (lo que los diferencia de los materiales estándar de biblioteca) dificultan esta unión. Además, no se han desarrollado los procedimientos de clasificación de datos hiperespectrales en la manera en que han sido desarrollados para la imagen multiespectral. Como consecuencia, la imagen multiespectral todavía representa en la actualidad la herramienta más importante de los sistemas de percepción remota.

## **Sistemas Sensor / Plataforma**

Dados los recientes desarrollos en sensores, una variedad de plataformas se encuentra ahora disponible para captar datos de sensores remotos. Aquí repasamos algunas de las combinaciones sensor / plataforma de mayor importancia que generalmente están disponibles para la comunidad de usuarios de SIG.

### **Fotografía Aérea**

La fotografía aérea es el método de percepción remota más antiguo y ampliamente usado. Cámaras montadas en aviones livianos que vuelan entre 200 y 15000 m capturan una gran cantidad de información detallada. Las fotos aéreas brindan un inventario visual instantáneo de una porción de la superficie terrestre y pueden ser usadas para crear mapas detallados.

Éstas son comúnmente tomadas por firmas comerciales de fotografía aérea que poseen y operan aviones especialmente modificados y equipados con cámaras de gran formato (23 cm x 23 cm) con calidad cartográfica. Las fotos aéreas también pueden ser tomadas con cámaras de formato pequeño (35 mm y 70 mm), manuales o montadas en aviones livianos no modificados.

Las configuraciones de las cámaras y plataformas pueden agruparse en términos de oblicuas y verticales. La fotografía aérea oblicua se toma con un ángulo en relación con el suelo. Las imágenes resultantes dan una vista parecida a la que se obtiene desde la ventana de un avión. Estas imágenes son más fáciles de interpretar que las de fotografías verticales, pero es difícil localizar y medir en ellas características para propósitos cartográficos.

La fotografía aérea vertical es tomada con una cámara que apunta hacia abajo perpendicularmente. Las imágenes resultantes muestran detalles del terreno en forma plana y pueden ser comparadas fácilmente con los mapas. Éstas son siempre muy buscadas, pero son particularmente útiles para los sondeos de recursos en áreas donde no hay mapas disponibles. La comparación de fotos viejas con fotos nuevas muestra los cambios dentro de un área a través del tiempo.

Las fotos aéreas verticales contienen desplazamientos leves debido al relieve, a la dirección e inclinación del avión y a la distorsión de las lentes. Las imágenes verticales pueden tomarse con superposición, generalmente cerca de un 60 % a lo largo de la línea de vuelo y por lo menos un 20 % entre líneas. Las imágenes superpuestas pueden observarse con un estereoscopio para crear una vista tridimensional, llamado modelo estereoscópico.

### **Fotografía en Formato Grande**

Las firmas comerciales de estudios aéreos usan aviones livianos de motores simples o gemelos equipados con cámaras cartográficas en formato grande. Estas cámaras, como la Wild RC-10, utilizan películas de 23 cm x 23 cm disponibles en rollos. Eastman Kodak Inc., entre otras, fabrica muchas variedades de cintas para película específicamente diseñadas para el uso en fotografía aérea. El negativo de la película se usa cuando las impresiones constituyen el producto requerido, mientras la película positiva se usa cuando se requieren transparencias. La película impresa permite agrandar la imagen con detalles, como las fotografías de tipo mural o gigantografías. Además, la película impresa es útil cuando múltiples impresiones deben ser distribuidas y usadas en estudios de campo.



## Fotografía en Formato Pequeño

Las cámaras en formato pequeño llevadas en aviones alquilados constituyen una alternativa económica para reemplazar la fotografía aérea en formato grande. Se requiere una cámara de 35 mm o 70 mm, un piloto con un avión liviano y algunos medios para procesar la película. Los sistemas de 35 mm son bastante convenientes debido a que existen laboratorios comerciales en casi todas partes del mundo que realizan este procesamiento a bajo costo.

Las fotografías oblicuas pueden tomarse con una cámara manual desde cualquier aeronave liviana; las fotografías verticales requieren una forma especial de montaje, apuntando desde la parte inferior o base del avión o colocada en la parte exterior de una ventana o puerta del mismo.

Las fotografías aéreas en formato pequeño tienen varias desventajas. Los aviones livianos no presurizados generalmente están limitados a alturas menores de 4000 m. Como el tamaño de la película es pequeño, tiene que sacrificarse la resolución o bien el área cubierta por marco. Debido a razones de distorsión en el sistema de la cámara, la fotografía en formato pequeño no puede usarse si se requieren mapas precisos. Por otra parte, las impresiones del tamaño de un mural con calidad de presentación no pueden realizarse con negativos pequeños. Sin embargo, la fotografía en formato pequeño puede ser muy útil para estudios de reconocimiento y también para muestreo de lotes.

## Fotografía Color

Las fotos color normales son producidas con un compuesto de tres capas de película con filtros que intervienen para aislar por separado las longitudes de onda roja, verde y azul en las diferentes capas de la película. Con la película color infrarroja, estas longitudes de onda se cambian a las longitudes más largas para producir un compuesto que posee reflejos aislados de las regiones de longitud de onda verde, roja y casi infrarroja. No obstante, debido a que el ojo humano no puede ver la luz infrarroja, se produce un compuesto de colores falsos al hacer que las longitudes de onda verdes aparezcan azules, las rojas se vean verdes y las infrarrojas se vean rojas.

Como alternativa al uso de películas color, también es posible agrupar varias cámaras y montarlas en un solo avión, cada una con película en blanco y negro y un filtro designado para aislar un rango específico de longitudes de onda. La ventaja de este montaje es que las bandas son accesibles de manera independiente y pueden ser mejoradas fotográficamente. Si se desea un compuesto en color, éste se puede crear más tarde con las bandas individuales.

Claramente, las fotografías no están en un formato que pueda ser usado de inmediato en un análisis digital. Es posible escanear fotografías con un escáner y luego crear juegos de datos multispectrales escaneando imágenes de bandas individuales o bien escaneando una imagen color separando las bandas. Sin embargo, la geometría de las fotos aéreas (la cual tiene una proyección de perspectiva central y un paralaje diferencial) es tal que resultan difíciles para usar directamente. Mayormente requieren ser procesadas con un software de fotogrametría especial para rectificar las imágenes y eliminar los efectos del paralaje diferencial.

## Videografía Aérea

Las cámaras y las grabadoras de video livianas, portátiles y económicas, pueden ser llevadas en vuelos charter. Asimismo, un número de pequeñas compañías dedicadas a la cartografía aérea ofrece la videografía como una opción de producción. Usando varias cámaras simultáneamente, cada una con un filtro diseñado para aislar un rango específico de longitudes de onda, es posible aislar bandas de imágenes multispectrales que pueden usarse individualmente o en combinación en forma de un compuesto color. Para el uso en el análisis digital, las tablas hardware de gráficos especiales conocidas como frame grabbers (sujetadores de marco s) pueden ser usadas para congelar cualquier marco dentro de una secuencia de video continua y convertirla a formato digital, usualmente en uno de los formatos de intercambio más populares como el TIF o el TARGA. Al igual que la fotografía de formato pequeño, la videografía aérea no puede utilizarse para mapas detallados, pero brinda un útil panorama general para los estudios de reconocimiento, y puede usarse en conjunto con el muestreo de lotes del suelo.

La fotografía ha probado ser una importante producción para la interpretación visual y la confección de mapas analógicos. No obstante, el desarrollo de plataformas satelitales, la necesidad relacionada de medir a distancia imágenes en formato digital y el deseo de imágenes digitales de alta consistencia ha dado lugar al desarrollo de escáners de estado sólido como formato principal para capturar datos de sensores remotos. Las características específicas de los sistemas particulares varían (incluyendo, en algunos casos, la eliminación de un mecanismo de escaneo real). Sin embargo, en la siguiente argumentación, se presenta un sistema de escaneo idealizado que es altamente representativo de los sistemas actualmente en uso.

La lógica básica de un sensor de escaneo es el uso de un mecanismo para el barrido (o captación) de un pequeño campo visual (conocido como *campo visual instantáneo* – IFOV) en una dirección de Oeste a Este, al mismo tiempo que el satélite se mueve de Norte a Sur. Estos movimientos juntos brindan los medios para componer una imagen raster completa del medio ambiente.

Una técnica de escaneo simple es usar un espejo rotativo que pueda hacer un barrido del campo visual de manera consistente de Oeste a Este. El campo visual es luego interceptado con un prisma que puede repartir la energía contenida en el IFOV entre sus componentes espectrales. Los detectores fotoeléctricos (de la misma naturaleza que la de aquellos encontrados en los metros de exposición de las cámaras fotográficas comunes) son entonces ubicados en la ruta de este espectro para medir la cantidad de energía detectada en varias partes del espectro electromagnético. Como el escaneo se mueve de Oeste a Este, estos detectores se sondean para obtener un juego de lecturas a lo largo del escaneo de Este a Oeste. Estas forman las columnas ubicadas a lo largo de una fila de imágenes raster – una por cada detector. El movimiento Norte-Sur del satélite luego posiciona el sistema para detectar la próxima fila, conduciendo en última instancia a la elaboración de un grupo de imágenes raster como un informe del reflejo de un rango de bandas espectrales.

Existen en la actualidad muchos sistemas satelitales en operación que recogen imágenes que luego son distribuidas a los usuarios. Muchos de los sistemas más comunes se describen a continuación. Cada tipo de datos satelitales ofrece detalles específicos que lo hacen más o menos apropiado para una aplicación en particular.

En general, hay dos características que pueden ayudar a guiar la elección de información satelital: la *resolución espacial* y la *resolución espectral*. La resolución espacial se refiere al tamaño del área sobre el suelo que se resume en un valor del dato en la imagen. Esto es el Campo Visual Instantáneo (IFOV) descrito anteriormente. La resolución espectral se refiere al número y a la amplitud de las bandas espectrales que detecta el sensor del satélite. Por otra parte, también deben considerarse los temas del costo y la disponibilidad de imágenes.

## LANDSAT

El sistema LANDSAT de satélites de percepción remota es operado actualmente por el EROS Data Center (<http://edc.usgs.gov>) del United States Geological Survey (Servicio Geológico de los Estados Unidos). Este es un nuevo acuerdo luego de un período de distribución comercial bajo el mando de la Earth Observation Satellite Company (EOSAT) (Compañía de Observación Satelital de la Tierra), la cual ha sido recientemente adquirida por la Space Imaging Corporation (Corporación de Imágenes Espaciales). Como resultado, el costo de las imágenes ha disminuido considerablemente para el beneficio de todos. Escenas completas o un cuarto de las mismas están disponibles en una variedad de medios de distribución, así como también los productos fotográficos de escenas MSS y TM en falso color y en blanco y negro.

Han habido siete satélites LANDSAT, el primero fue lanzado en 1972. El satélite LANDSAT 6 se perdió en el lanzamiento. Por otra parte, hasta el momento de escribirse este manual, el LANDSAT 5 aún está operando. El LANDSAT 7 fue lanzado en abril de 1999.

El LANDSAT lleva dos sensores multispectrales. El primero es el *Multi-Spectral Scanner* (MSS) que adquiere imágenes en cuatro bandas espectrales: azul, verde, roja e infrarroja cercana. El segundo es el *Thematic Mapper* (TM) que capta siete bandas: azul, verde, roja, infrarroja cercana, dos infrarrojas medias y una infrarroja termal. El MSS tiene una resolución espacial de 80 metros, mientras que la del TM es de 30 metros. Ambos sensores captan un área de 185 km. de ancho, pasando cada día a las 09:45 hora local (EE.UU), y retornando cada 16 días. El LANDSAT 7, presenta iguales características que el TM, con la incorporación de una banda pancromática de 15 m. (de resolución).

## SPOT

El *Système Pour L'Observation de la Terre* (SPOT) ([www.spot.com](http://www.spot.com)) fue lanzado en 1985 y desde entonces ha sido operado por un consorcio francés. Los satélites SPOT llevan dos sensores de barrido (pushbroom) de High Resolution Visible (HRV) (Alta Resolución Visible) 5 que operan en modo multispectral o pancromático. Las imágenes multispectrales poseen una resolución espacial de 20 metros, mientras que las imágenes pancromáticas tienen una resolución de 10 metros. Los satélites SPOT 1-3 ofrecen tres bandas multispectrales: Verde, Roja e Infrarroja. El SPOT 4, lanzado en 1998, ofrece las tres mismas bandas más una banda infrarroja de onda corta. La banda pancromática del los SPOT 1-3 es de 0,51-0,7  $\mu$ m, mientras que la del SPOT 4 es de 0,61 -0,68  $\mu$ m. El SPOT <sup>5</sup> fue lanzado en el 2002. Los principales avances sobre el SPOT 4 incluyen: una resolución más alta para las bandas pancromáticas de 2,5 y 10 metros; una resolución más alta para las imágenes multispectrales de 10 metros en las tres bandas visibles y del infrarrojo cercano, y un instrumento dedicado a la adquisición de pares estereoscópicos a lo largo de la traza.

---

<sup>5</sup>El sensor de empuje tiene una producción como un escáner. Sin embargo, no tiene un movimiento de escaneo real. Por el contrario, el sensor.

Todas las imágenes SPOT cubren un área de 60 kilómetros de ancho. El sensor SPOT puede ser apuntado para captar rutas adyacentes. Esto le permite al instrumento adquirir una repetitividad de 12 veces de las imágenes de cualquier área durante su período orbital de 26 días.

La compañía Spot Image Inc. vende una serie de productos, incluyendo imágenes digitales como opción de medio de distribución. Las imágenes existentes pueden comprarse, o bien pueden ordenarse nuevas adquisiciones de imágenes. Los clientes pueden pedir que el satélite apunte a cualquier dirección en particular para nuevas adquisiciones.

## **IKONOS**

El satélite IKONOS fue lanzado en 1999 por la Space Imaging Corp. ([www.spaceimaging.com](http://www.spaceimaging.com)) y fue la primera empresa comercial para la adquisición y distribución de imágenes satelitales de alta resolución. El IKONOS completa su órbita alrededor de la tierra en 98 minutos a una altura de 680 Km., pasando sobre una longitud dada a la misma hora (aproximadamente 10:30 A.M.) cada día. Los productos informativos del IKONOS incluyen imágenes pancromáticas de 1 metro (0,45 – 0,90 mm), multiespectrales de 4 metros de resolución (azul: 0,45 – 0,52 mm, verde: 0,51 – 0,60 mm, rojo: 0,63 – 0,70 mm e infrarrojo cercano: 0,76 – 0,85 mm) tomadas en áreas de 10,5 km. Las imágenes espaciales brindan una variedad de productos informativos. Los clientes pueden personalizar sus adquisiciones.

## **QuickBird**

El satélite QuickBird fue lanzado en el 2001 por Digital Globe ([www.digitalglobe.com](http://www.digitalglobe.com)). Éste ofrece imágenes de resolución aún mayor que el IKONOS, sobre una base comercial. Su única banda pancromática tiene una resolución de 61 cm y su imagen multiespectral una de 2,44 metros. Los productos del QuickBird incluyen la banda pancromática (0,45 – 0,90 mm) y cuatro bandas multiespectrales (azul: 0,45 – 0,52 mm, verde: 0,52 – 0,60 mm, rojo: 0,63 – 0,69 mm, e infrarrojo cercano: 0,76 – 0,90 mm) tomadas en áreas de 16,5 km. La compañía Digital Globe ofrece una variedad de productos informativos.

## **IRS**

La Indian Space Research Organization (Organización de Investigación Espacial de la India) actualmente posee 5 satélites en el sistema IRS, con al menos 7 planeados para el 2004. Estos datos son distribuidos por ANTRIX Corp. Ltd (la extensión comercial de la Indian Space Research Organization) y también por la Space Imaging Corporation (Corporación de Imágenes Espaciales de EE.UU.). Las capacidades más sofisticadas son ofrecidas por los satélites IRS-1C e IRS-1D, los cuales proveen juntos una cobertura global continua con los siguientes sensores:

IRS-Pan: 5,8 m de resolución pancromática

IRS-LISS3<sup>6</sup>: 23,5 m de resolución multiespectral en las siguientes bandas:

Verde (0,52-0,59 mm)

Rojo (0,62-0,68 mm)

Infrarrojo cercano (0,77-0,86 mm)

Infrarrojo de onda corta (1,55-1,7 mm)

IRS-WiFS<sup>7</sup>: 180 m multiespectral en las siguientes bandas:

Rojo (0,62-0,68 mm)

Infrarrojo cercano (0,77-0,86 mm)

## **NOAA-AVHRR**

El *Advanced Very High Resolution Radiometer* (AVHRR) (Radiómetro Avanzado de Muy Alta Resolución) es llevado a bordo de una serie de satélites operados por la U.S. National Oceanic and Atmospheric Administration (NOAA). Éste adquiere datos sobre un área de 2400 km de ancho diariamente. El AVHRR recoge cinco bandas: roja, infrarrojo cercano y tres infrarrojos termales. La resolución espacial del sensor es de 1,1 km y este dato se denomina Cobertura del Área Local (Local Area Coverage-LAC). Para el estudio de áreas muy amplias, también está disponible una versión probada con una resolución de alrededor de 4 km que se denomina Cobertura del Área Global (Global Area Coverage-GAC).

Los AVHRR pueden ser de resolución espacial “alta” para aplicaciones meteorológicas, pero las imágenes ilustran sólo patrones amplios y detalles pequeños para estudios terrestres. En cambio, sí poseen una resolución temporal alta, para mostrar áreas amplias en una base diaria y son, por lo tanto, una opción popular para el monitoreo de

---

<sup>6</sup> LISS = Linear Imaging and Self Scanning Sensor (Imagen Lineal y Sensor de Autoescaneo). El formato de la imagen es de aproximadamente 140 km x 140 km.

<sup>7</sup> WiFS = Wide

grandes áreas. La imagen AVHRR es usada por varias organizaciones involucradas en la predicción del hambre y es parte integral de muchas actividades de alerta temprana.

## **RADARSAT**

RADARSAT es un satélite de observación terrestre lanzado en noviembre de 1995 por la Canadian Space Agency (Agencia Espacial Canadiense). Los datos son distribuidos por RADARSAT International (RSI) de Richmond,

British Columbia, Canadá (o a través de Space Imaging en EE.UU.). La resolución espacial de la imagen SAR band C oscila entre los 8 y 100 metros por pixel y el intervalo de repetición de la cobertura terrestre es de 24 días. Los sensores pueden apuntar al sitio de interés, lo que permite recoger imágenes RADAR estereoscópicas. Las señales

RADAR también penetran la capa de nubes, por lo que accede a áreas no disponibles para otros sistemas de percepción remota. En contraste con otras imágenes percibidas por sensores remotos, la señal de retorno RADAR es más afectada en el blanco por características eléctricas y físicas (principalmente de textura) que por su reflexión y su patrón espectral. Consecuentemente, requiere una interpretación especial y técnicas de geo-registro espacial. Comparada con otros tipos de imágenes captadas por sensores remotos, el uso de los datos del RADAR aún se encuentra en su etapa inicial pero con un fuerte potencial.

## **ERS**

El ERS-1 y el ERS-2 (European Remote Sensing Satellite) (<http://earth.esa.int/ers/>) (Satélite Europeo de Percepción Remota) fueron desarrollados por la Agencia Espacial Europea. Estos sistemas idénticos constituyen un complemento interesante para los demás productos comerciales de imágenes ya que brindan una variedad de formatos de banda C RADAR para la producción de imágenes. Para aplicaciones en SIG, la principal producción de interés es la imagen lateral RADAR (SAR) que capta áreas 100 km de ancho con 30 metros de resolución. Esto puede ser de interés para una variedad de aplicaciones, incluyendo estudios de vegetación y proyectos cartográficos donde la nubosidad es un problema persistente.

## **JERS**

El Japanese Earth Resource Satellite (Satélite Japonés para Recursos Terrestres) ofrece una imagen lateral en banda L RADAR y una resolución de 18 m. Esta es una banda con longitud de onda sustancialmente más larga que la típica banda C usada en aplicaciones para recursos terrestres. La banda L RADAR es capaz de penetrar la vegetación así como también arena blanda, y es usada principalmente en aplicaciones cartográficas de tipo geológicas, topográficas y costeras. Los datos obtenidos por el JERS están disponibles en EE.UU. a través de la Space Imaging Corporation (corporación de Imágenes Espaciales).

## **AVIRIS**

El AVIRIS es un sistema experimental desarrollado por el Jet Propulsion Lab (JPL) (Laboratorio de Propulsión a Chorro) que produce datos hiperespectrales. Capta datos en 224 bandas sobre el mismo rango de longitud de banda que el LANDSAT.

## **TERRA**

En 1999, un proyecto conjunto entre Canadá, Japón y EE.UU. lanzó el primero de una serie de satélites de la NASA Earth Observing System (EOS) (Sistema de Observación Terrestre de la NASA). El satélite EOS AM-1 posee cinco instrumentos (CERES, MISR, MODIS, ASTER, y MOPITT) que recoge datos terrestres y atmosféricos de riqueza sin precedentes. Los datos ya se encuentran disponibles en sitio web de USGS <http://edcimswww.cr.usgs.gov/pub/imswelcome/>. El satélite EOS AM-1 vuela en una órbita casi polar, sincronizada con el sol y desciende por el Ecuador alrededor de la 10:30 A.M. Para el usuario SIG, los dos instrumentos prometedores son el ASTER y el MODIS.

El sensor ASTER a bordo de la plataforma del EOS AM-1, obtiene imágenes de alta resolución en 14 bandas de 15 a 90 metros de resolución. Tres bandas son recogidas con 15 m en las longitudes de ondas del visible e infrarrojo cercano (0,5-0,90  $\mu\text{m}$ ) en áreas de 60 km. Una banda adicional es recogida a 15 m, y está hecha para producir imágenes estereoscópicas de la misma órbita. Seis bandas infrarrojas de onda corta (1,6-2,5  $\mu\text{m}$ ) son captadas con 30 m de resolución terrestre en áreas de 60 km. Otras cinco bandas infrarrojas termales (8-12  $\mu\text{m}$ ) son recogidas a 90 m en áreas de 60 km. Los productos ASTER incluyen: radiaciones y reflejos espectrales de la superficie terrestre; temperatura superficial y emisividad, mapas digitales de elevación obtenidos de imágenes estereoscópicas, mapas de composición de la superficie y de la vegetación, productos de información sobre las nubes, mares, hielos y polos, y observación de peligros naturales.

# Procesamiento de Imágenes Digitales

## Resumen

Como resultado de los escáner de estado sólido y otros dispositivos raster de entrada, ahora tenemos disponibles imágenes digitales raster de datos espectrales reflejados. La principal ventaja de tener estos datos en formato digital es que nos permiten aplicar a los datos de las imágenes técnicas de análisis por computadora – un campo de estudio llamado *Procesamiento Digital de Imágenes*.

El Procesamiento Digital de Imágenes implica en gran medida cuatro operaciones básicas: **restauración, mejoramiento, clasificación y transformación de imágenes**. La *restauración de imágenes* está relacionada con la corrección y calibración de imágenes para obtener una representación de la superficie terrestre tan real como sea posible – consideración fundamental para todas las aplicaciones. El *mejoramiento de imágenes* está principalmente relacionado con la modificación de imágenes para optimizar su apariencia ante el sistema visual. El análisis visual es un elemento clave, aún en el procesamiento digital de imágenes, y los efectos de estas técnicas pueden ser cruciales. La *clasificación de imágenes* se refiere a la interpretación de imágenes asistida por computadora – operación vital para el SIG. Finalmente, la *transformación de imágenes* se ocupa de la derivación de imágenes nuevas como resultado de algún tratamiento matemático de las bandas originales de la imagen.

Para poder realizar las operaciones presentadas en esta sección, es necesario tener acceso a un software de procesamiento de imágenes. IDRISI entra en esta categoría. Mientras se lo conoce principalmente como un sistema software SIG, éste además ofrece un juego completo de capacidades para el procesamiento de imágenes.

## Restauración de Imágenes

Las imágenes del medio ambiente captadas con un sensor remoto son por lo general tomadas a una gran distancia de la superficie de la tierra. Como resultado, hay una ruta atmosférica sustancial que la energía electromagnética debe atravesar antes de llegar al sensor. Dependiendo de las longitudes de onda involucradas y de las condiciones atmosféricas (como las partículas de materia, humedad y turbulencia), la energía entrante puede estar bastante modificada. El sensor mismo puede entonces modificar el carácter de esos datos ya que puede combinar una variedad de componentes mecánicos, ópticos y eléctricos que modifican o enmascaran la energía radiante medida. Además, mientras la imagen está siendo escaneada, el satélite sigue una ruta que está sujeta a variaciones menores al mismo tiempo que la tierra se mueve por debajo de éste. La geometría de la imagen está por lo tanto en un constante flujo. Por último, la señal necesita ser medida de vuelta hacia la tierra, y subsecuentemente, recibida y procesada para producir los datos finales que recibimos. En suma, una variedad de perturbaciones sistemáticas y aparentemente aleatorias pueden combinarse para degradar la calidad de la imagen que finalmente recibimos. La restauración de imágenes pretende remover estos efectos degradantes.

En general, la restauración de imágenes puede dividirse en dos subáreas de *restauración: radiométrica y geométrica*.

### Restauración Radiométrica

La restauración radiométrica se refiere a la eliminación o disminución del grado de distorsión de la energía electromagnética registrada por cada detector. Una variedad de agentes puede provocar distorsión en los valores grabados para las celdas de las imágenes. Algunas de las distorsiones más comunes para las cuales existen procedimientos de corrección incluyen:

**valores** uniformemente elevados, debido a la niebla atmosférica, la cual dispersa preferentemente bandas de longitud de onda corta (particularmente las longitudes de onda azul);

**rayado**, debido a la descalibración de los detectores;

**ruido aleatorio**, debido a la actuación impredecible y no sistemática del sensor o de la transmisión de los datos; y

**caída de la línea del escáner**, debido a la pérdida de la señal de algunos detectores.

También corresponde incluir aquí los procedimientos que se usan para convertir los valores puros de reflejo relativo sin unidad (conocidos como números digitales o DN) de las bandas originales en verdaderas medidas de poder reflectivo (radiación).

Véase el capítulo **Restauración de Imágenes** para un tratamiento más detallado de la restauración radiométrica y de cómo ésta puede implementarse en IDRISI.

## Restauración Geográfica

Para fines cartográficos, es esencial que cualquier forma de imagen percibida por un sensor remoto sea registrada correctamente en la base del mapa propuesto. Con las imágenes satelitales, la gran altura de la plataforma sensora resulta en desplazamientos mínimos de la imagen provocados por el relieve. Como resultado, el registro puede lograrse generalmente a través del uso de un proceso<sup>8</sup> de transformación sistemática llamado *rubber sheet* (lámina de goma) que tuerce suavemente la imagen (a través del uso de ecuaciones polinominales) basándose en las posiciones conocidas de un grupo de puntos de control ampliamente dispersados. Esta capacidad es brindada en IDRISI por el módulo RESAMPLE (Remuestreo).

Con las fotografías aéreas, sin embargo, el proceso es más complicado. No sólo existen distorsiones sistemáticas relacionadas con el cabeceo del avión y la variación en la altitud, sino que también el relieve topográfico variable provoca distorsiones muy irregulares (diferencia de paralaje) que no pueden ser eliminadas con el procedimiento de transformación *rubber sheet* (lámina de goma). En estos casos, es necesario utilizar la rectificación fotogramétrica para remover estas distorsiones y proveer medidas precisas de los mapas<sup>9</sup>. Si esto falla, las porciones centrales de las fotografías de gran altitud pueden ser remuestreadas con algo de éxito.

El módulo RESAMPLE es de gran importancia, y es esencial que uno aprenda a usarlo con efectividad. Aprender esto también requiere un profundo entendimiento de los sistemas de referencia y de sus parámetros asociados tales como los datos y las proyecciones. El capítulo de **Georeferenciamiento** brinda una discusión con detenimiento de estos temas.

## Mejoramiento de Imágenes

El mejoramiento de imágenes se ocupa de la modificación de imágenes para adecuarlas más a las capacidades de la visión humana. Más allá de la cantidad de intervención digital, el análisis visual siempre juega un papel central en todos los aspectos de la percepción remota. Mientras la gama de técnicas para el mejoramiento de imágenes es amplia, los siguientes temas fundamentales forman la columna vertebral de esta área:

### Área de Contraste

Los sensores digitales poseen un amplio rango de valores de salida para acomodar los valores de reflexión muy variables que pueden encontrarse en diferentes ambientes. Sin embargo, en cualquier medio ambiente, a menudo se presenta el caso en que sólo un pequeño rango de valores ocurre en la mayoría de las áreas. Las distribuciones de los niveles de gris tienden entonces a estar bastante alteradas. Los procedimientos de manipulación de contraste son por lo tanto esenciales para la mayoría de los análisis. La Figura 3-6 muestra la Banda TM 3 (rojo visible) y su histograma. Fíjese que los valores de la imagen están bastante alterados. La imagen derecha de la figura muestra la misma banda de imagen después de que un área lineal entre los valores 12 y 60 ha sido aplicada. En IDRISI, este tipo de mejoramiento o ajuste de contraste puede realizarse interactivamente a través de las Propiedades de las Capas del Diseñador (Composer's Layer Properties) mientras se visualiza la imagen. Esto es normalmente utilizado para análisis visuales únicamente – los valores originales de los datos son usados en análisis numéricos. Las imágenes nuevas con valores ampliados se producen con el módulo STRETCH (Estiramiento).

---

<sup>8</sup> Las imágenes de satélites basados en los escáners contienen una variedad de problemas geométricos inherentes como la deformación (causada por la rotación de la Tierra debajo del satélite mientras éste se encuentra escaneando una imagen completa) y la distorsión del escáner (causada por el hecho de que el campo visual instantáneo, IFOV, cubre más territorios al final de las líneas del escáner, donde el ángulo visual es muy oblicuo, que en la parte central). Con las imágenes satelitales comercializadas, como las del LANDSAT, IRS o SPOT, la mayoría de los elementos de la restauración geométrica sistemática asociados con la captación de imágenes son corregidos por los distribuidores de las imágenes. Entonces, para el usuario final, la única operación geométrica que generalmente necesita ser realizada es un remuestreo *rubber sheet* (lámina de goma) para rectificar la imagen para una base cartográfica. Muchas distribuciones comerciales realizan esta rectificación con un costo adicional.

<sup>9</sup> La fotogrametría es la ciencia que realiza medidas espaciales a partir de fotografías aéreas. Para proveer una rectificación completa, es necesario poseer imágenes estereoscópicas – fotos que se superponen lo suficiente (Ej., 60% en la dirección a lo largo de la ruta y 10% entre las líneas de vuelo) como para brindar dos imágenes independientes para cada parte del paisaje. Al usar estos pares estereoscópicos y los puntos de control del suelo de posición y altura conocidas, es posible recrear por completo la geometría de las condiciones visuales y, por lo tanto, no sólo rectificar las medidas de dichas imágenes, sino también derivar las medidas de la altura del terreno. Las fotografías rectificadas se llaman ortofotos. Las medidas de altura pueden usarse para producir modelos de elevación digital.






Figura 3-6

## Generación de Compuestos

Para el análisis visual, los compuestos color hacen un uso total de las capacidades del ojo humano. Dependiendo del sistema de gráficos en uso, la generación de compuestos va desde la simple selección de las bandas a utilizar, hasta procedimientos más complejos de combinaciones de bandas y áreas de contraste asociadas. La Figura 3-7 muestra varios compuestos hechos con diferentes combinaciones de bandas a partir del mismo grupo de imágenes TM (Vea la Figura 3-5 para las definiciones de bandas TM). El módulo COMPOSITE (Compuestos) de IDRISI se usa para construir imágenes compuestas de tres bandas y 24 bits para análisis visuales.





Figura 3-7

## Filtrado Digital

Una de las capacidades más intrigantes del análisis digital es la habilidad para aplicar filtros digitales. Los filtros pueden ser usados para proveer un realce de los bordes (a veces llamado *crispening*), para eliminar la borrosidad de las imágenes, y para aislar los lineamientos y las tendencias direccionales, para mencionar unas pocas. El módulo FILTER (Filtros) de IDRISI se usa para aplicar los filtros estándar y para construir y aplicar filtros definidos por el usuario.

## Pansharpening

Pansharpening es el proceso de combinar imágenes multiespectrales de baja resolución con imágenes pancromáticas de alta resolución. Por lo general, las bandas pancromáticas asociadas con la mayoría de los sistemas, ej.: SPOT, IKONS o QuickBird, son capturadas a través del rango visible del espectro, el cual les brinda una resolución más alta y, por lo tanto, les da mejor detalle de forma y textura. Sin embargo, lo que se gana en claridad, se pierde en términos de las propiedades espectrales. Ésto no ocurre con las bandas multiespectrales. La combinación de los dos resultados incrementa la resolución de las imágenes multiespectrales al mismo tiempo que conserva su información espectral.



**Figura 3-8.** Combinación pancromática con imágenes de Quickbird, multiespectral a 2,4 metros, pancromática a 0,6 metros. La imagen original está a la izquierda. La imagen de la derecha muestra el resultado luego de la combinación. Note la resolución espacial incrementada y la textura aumentada.

En IDRISI, el módulo PANSHARPEN es utilizado para agudizar imágenes multiespectrales con la banda pancromática. Existen tres métodos disponibles: transformación de espacio y color, análisis de los componentes principales y regresión local.

## Clasificación de Imágenes

La clasificación de imágenes se refiere a la interpretación asistida por computadora de imágenes de sensores remotos. Los procedimientos involucrados son tratados en detalle en el capítulo titulado **Clasificación de Imágenes de Sensores Remotos**. Esta sección brinda un breve resumen.

Aunque algunos procedimientos son capaces de incorporar información acerca de las características de las imágenes tales como la textura y el contexto, gran parte de la clasificación de imágenes sólo se basa en la detección de firmas espectrales (es decir, patrones de respuesta espectral) de las clases de cubierta terrestre. El éxito que esto puede adquirir depende de dos factores: 1) la presencia de firmas distintivas para las clases de cubierta terrestre de interés en el grupo de bandas en uso; 2) la habilidad para distinguir con precisión estas firmas de otros patrones de respuesta espectral que pueden presentarse.

Existen dos enfoques generales en la clasificación de imágenes: *supervisado* y *no supervisado*. Se diferencian en la manera de realizar la clasificación. En el caso de la clasificación supervisada, el sistema software delinea tipos de cubierta terrestre específicos sobre datos estadísticos de caracterización extraídos de ejemplos conocidos en la imagen (conocidos como sitios de entrenamiento). Con la clasificación no supervisada, en cambio, se utiliza un software de agrupamientos (clustering) para descubrir los tipos de cubierta terrestre más comunes. Luego, en un paso posterior, el analista provee interpretaciones de esos tipos de cubierta.

### Clasificación Supervisada

El primer paso en la clasificación supervisada es identificar ejemplos de las clases de información de interés (es decir, tipos de cubierta terrestre) en la imagen. Éstos se llaman *sitios de entrenamiento* (training sites). El sistema software se usa por lo tanto para desarrollar una caracterización estadística de los reflejos para cada clase de información. Este paso a menudo es llamado *análisis de firmas* (signature análisis) y puede incluir el desarrollo de una caracterización tan simple como el medio o el rango de los reflejos sobre cada banda, o tan compleja como el análisis detallado del medio, desviaciones y co-desviaciones sobre todas las bandas.

Una vez lograda la caracterización estadística de cada clase de información, la imagen es clasificada a partir del examen de los valores por cada pixel y de la toma de decisión acerca de a cuál de las firmas ésta se asemeja más. Hay varias técnicas llamadas *clasificadores*, para tomar estas decisiones. La mayoría de los software de Procesamiento de Imágenes ofrece muchas de estas técnicas, basadas en reglas de decisión variable. IDRISI ofrece una amplia gama de opciones que se dividen en tres grupos, dependiendo de la naturaleza de la producción deseada y de la naturaleza de las bandas de entrada.

### Clasificadores Rígidos

La característica distintiva de los clasificadores rígidos es que todos toman una decisión definitiva acerca de la clase de superficie terrestre a la que pertenece cualquier pixel. IDRISI ofrece gran cantidad de clasificadores supervisados en este grupo. Los paralelepípedos (PIPED), distancia mínima a la media (MINDIST), probabilidad máxima (MAXLIKE), análisis discriminante lineal (FISHER), Red Neural con Función de Base Radial (RBFNN) y la red neural Fuzzy ARTMAP producen solo un mapa de clasificadores rígidos. Otros pueden producir tanto mapas blandos como rígidos. Éstos incluyen: red neural de perceptrones multicapas (MLP), red neural de mapas auto-organizados (SOM), vecino más cercano a k (KNN), análisis del árbol clasificador (CTA). Todos estos clasificadores solo se diferencian en la forma en que desarrollan y utilizan la caracterización estadística de los datos del sitio de entrenamiento. De la lista, el procedimiento de probabilidad máxima es sin dudas el clasificador más ampliamente utilizado en la clasificación de imágenes tomadas con sensores remotos.

La rutina de clasificación por segmentación es un clasificador rígido característico de IDRISI. El módulo SEGCLASS clasifica las imágenes usando una regla algorítmica de mayoría que se aplica a los segmentos de imágenes creados por el módulo SEGMENTATION.

## Clasificadores Blandos

Al contrario de los clasificadores rígidos, los clasificadores blandos no toman una decisión definitiva acerca de la clase de cubierta terrestre a la cual pertenece cada pixel. Éstos desarrollan declaraciones del grado al que pertenece cada pixel en cada una de las clases de cubierta terrestre en consideración. Entonces, por ejemplo, un clasificador blando puede indicar que un pixel tiene una probabilidad de 0,72 de representar bosque, una probabilidad de 0,24 de ser pastura y una probabilidad de 0,04 ser suelo desnudo. Un clasificado rígido resuelve esta incertidumbre concluyendo que el pixel representa bosque. Sin embargo, un clasificador blando pone esta incertidumbre explícitamente disponible, para cualquier tipo de propósitos. Por ejemplo, el analista puede concluir que la incertidumbre nace porque el pixel contiene más de un tipo de cubierta terrestre y puede usar las probabilidades como indicadores de la proporción relativa de cada uno. Esto se conoce como clasificación *sub-pixel*. Alternativamente, el analista puede concluir que la incertidumbre nace debido a datos de sitios de entrenamiento no representativos y por lo tanto debe combinar estas probabilidades con otra evidencia antes de *endurecer* la decisión hacia una conclusión final. IDRISI ofrece cuatro clasificadores blandos (BAYCLASS, MAHALCLASS, BELCLASS y FUZCLASS).

Los resultados de los cuatro pueden ser endurecidos usando el módulo HARDEN (Endurecer). La diferencia entre ellos está relacionada con la lógica por la cual se especifica la incertidumbre - Bayesiana, Dempster-Shafer y Fuzzy Sets. Además, el sistema ofrece una variedad de herramientas adicionales específicamente diseñadas para el análisis de mezclas sub-pixel (Ej., UNMIX, FUZSIG, MIXCALC y MAXSET).

## Clasificadores Hiperespectrales

Todos los clasificadores mencionados anteriormente operan sobre imágenes multiespectrales – imágenes en donde varias bandas espectrales han sido captadas simultáneamente como componentes de imágenes independientemente accesibles. Al extender esta lógica a muchas bandas, se produce lo que se ha conocido como imagen *hiperespectral*.

Aunque esencialmente no haya ninguna diferencia entre las imágenes hiperespectrales y multiespectrales (es decir, sólo difieren en grado), el volumen de datos y la alta resolución espectral de las imágenes hiperespectrales sí provoca diferencias en la forma en que son manejadas. IDRISI brinda utilidades especiales para crear firmas hiperespectrales de sitios de entrenamiento o bien de bibliotecas de patrones de respuesta espectral desarrollados bajo condiciones de laboratorio (HYPERSIG) y una rutina automática de extracción de firmas hiperespectrales (HYPERAUTOSIG). Estas firmas pueden ser aplicadas entonces en cualquiera de los varios clasificadores hiperespectrales: Ángulo Espectral Cartográfico (HYPERSAM), Distancia Mínima Hiperespectral (HYPERMIN), Eliminación de la Mezcla de las Líneas Espectrales (HYPERUNMIX), Proyección Ortogonal Subespacial (HYPEROSP), Análisis del Área de Absorción (HYPERABSORB).

También se encuentra disponible un clasificador no supervisado (vea la próxima sección) para las imágenes hiperespectrales (HYPERUSP).

## Clasificación No Supervisada

En contraste con la clasificación supervisada, en la que le indicamos al sistema el carácter (es decir, la firma) de las clases de información que estamos buscando, la clasificación no supervisada no requiere un avance de información acerca de las clases de interés. Ésta examina, en cambio, los datos y los divide en los grupos espectrales naturales más prevalecientes, o grupos, presentes en los datos. El analista identifica, entonces, estos grupos como clases de cubierta terrestre a través de una combinación de familiaridad con las visitas verdaderas a la región y el suelo.

La lógica con la que trabaja la clasificación no supervisada se conoce como *análisis cluster o de grupos*, y en IDRISI es principalmente aplicado en el módulo CLUSTER. Este módulo realiza la clasificación basándose en un grupo de imágenes de entrada usando una técnica máxima de histograma multi-dimensional. Es importante reconocer, sin embargo, que los procedimientos de agrupamiento de clasificación no supervisada no son clases de información, sino clases espectrales (es decir, agrupan características, pixeles, con patrones de reflexión similares). Es por lo general el caso en el que el analista necesita reclasificar las clases espectrales en clases de información. Por ejemplo, el sistema puede identificar clases para asfalto y cemento que el analista luego puede agrupar y crear una clase de información llamada pavimento.

Aunque resulte atractivo conceptualmente, la clasificación no supervisada ha sido tradicionalmente entorpecida por algoritmos muy lentos. Sin embargo, el procedimiento de agrupamiento brindado por IDRISI es extraordinariamente rápido (sin dudas el más rápido del mercado) y puede por lo tanto usarse iterativamente en conjunción con datos verdaderos del suelo para arribar a una clasificación muy precisa. Con los procedimientos correctos de la verdad de

campo y de evaluación de la exactitud, esta herramienta puede proveer un medio marcadamente rápido para producir datos de calidad sobre la cubierta terrestre en una base continua.

El módulo KMEANS es una verdadera rutina de agrupación de promedios k con varias reglas de agrupación (semilla aleatoria, partición aleatoria y eje diagonal) y umbrales con criterio de detención. Dos de los módulos de redes neurales de IDRISI también permiten la clasificación no supervisada, mapas auto-organizados (SOM) y Fuzzy ARTMAP. Además se incluyen las rutinas ISODATA y CHAINCLUSTER.

Además de las técnicas mencionadas anteriormente, hay dos módulos que unen ambas clasificaciones: supervisada y no supervisada. El ISOCLUST usa un procedimiento llamado *Análisis de Cluster de Autoorganización* para clasificar hasta 7 bandas puras en las que el usuario especifica el número de grupos a procesar. El procedimiento emplea el módulo CLUSTER para iniciar una cantidad de grupos que generan una aplicación iterativa del procedimiento MAXLIKE, en el cual cada paso usa los resultados del paso anterior como los sitios de entrenamiento para este procedimiento supervisado. El resultado es una clasificación no supervisada que converge en una etapa final de elementos estables usando un enfoque supervisado (por eso el concepto de “autoorganización”). El MAXSET es también, en su esencia, un procedimiento supervisado. No obstante, mientras el procedimiento comienza con sitios de entrenamiento que caracterizan clases individuales, éste resulta en una clasificación que no sólo incluye estas clases específicas sino también (aunque se desconozcan) mezclas que pueden llegar a existir. Entonces, el resultado final tiene en gran medida el perfil de aquel de un enfoque no supervisado.

## Evaluación de la Exactitud

Un paso vital en el proceso de clasificación, tanto supervisada como no supervisada, es la evaluación de la precisión de las imágenes finales. Esto implica identificar un grupo de lugares (con el módulo SAMPLE) que son visitados en el campo. La cubierta terrestre encontrada en el campo es luego comparada con aquella que fue confeccionada en la imagen del mapa del mismo lugar. Las evaluaciones de precisión estadísticas puede ser derivada para toda el área de estudio, así como también para clases individuales (usando el ERRMAT).

En un enfoque iterativo, la matriz de errores producida (a veces llamada *matriz de confusión*), puede ser usada para identificar tipos de cubierta particulares para los cuales los errores son más de los deseados. La información en la matriz acerca de qué cubiertas están siendo incluidas por error en una clase en particular (*errores de comisión*) y aquellas que están siendo excluidas por error (*errores de omisión*) de esa clase pueden usarse para afinar el enfoque de clasificación.

## Transformación de Imágenes

El Procesamiento de Imágenes Digitales ofrece un rango ilimitado de transformaciones posibles para la información tomada con sensores remotos. IDRISI ofrece varios procesos de transformación incluyendo Análisis de los Componentes Principales (PCA) el cual permite transformaciones estandarizadas y no estandarizadas, centradas y normalizadas, modo T y modo S; Análisis de los Componentes Canónicos (CANCOMP); Análisis de Correlación Canónica (CANCOR); Fracción de Ruido Mínimo (MNF) que maximiza la señal según la proporción del ruido; Análisis Fourier Temporal (TFA) que realiza análisis armónico sobre imágenes temporales; Transformación del Espacio a Color (COLSPACE); cálculos de textura (TEXTURE); transformaciones térmicas de cuerpos oscuros (THERMAL); índices de vegetación verde (VEGINDEX) y Tasseled Cap (TASSCAP). Además posee una amplia variedad de transformaciones diseñadas especialmente (como el cálculo de proporciones en imágenes) que pueden llevarse a cabo efectivamente con la función Image Calculator. Se mencionan específicamente a continuación dos transformaciones (VEGINDEX and PCA), debido a su significado especial en aplicaciones de monitoreo ambiental.

## Índices de Vegetación


Hay una variedad de índices de vegetación que han sido desarrollados para ayudar al monitoreo de la vegetación. La mayoría están basados en las interacciones diferentes entre la vegetación y la energía electromagnética en las longitudes de ondas del rojo e infrarrojo cercano. Observe la Figura 3-4, que incluye un patrón de respuesta espectral generalizado para la vegetación de hoja ancha y verde. Como se puede ver, la reflexión en la región roja (0,6-0,7  $\mu$  aprox.) es baja debido a la absorción hecha por los pigmentos de las hojas (principalmente la clorofila). La región infrarroja (0,8-0,9  $\mu$  aprox.) en cambio, muestra una reflexión alta debido a la difusión por parte de la estructura de las células de las hojas. Un índice de vegetación muy simple puede entonces lograrse comparando la medida de la reflexión en el infrarrojo con la de la reflexión en el rojo.

Aunque se ha desarrollado un número de variantes de esta lógica básica, la que ha recibido más atención es el *índice de vegetación de la diferencia normalizada* (NDVI). Éste se calcula de la siguiente manera:

$$\text{NDVI} = (\text{NIR} - \text{R}) / (\text{NIR} + \text{R})$$

donde NIR = Infrarrojo cercano  
R = Rojo

La Figura 3-9 muestra el NDVI calculado con las bandas 3 y 4 TM para la misma área que se muestra en las Figuras 3-5, 3-6 y 3-7.



**Figura 3-9**

Este tipo de cálculo es bastante simple para un SIG raster o un sistema software de Procesamiento de Imágenes, y el resultado se ha mostrado de manera tal que se relacione bien con las medidas de la biomasa. Aunque el NDVI necesite una calibración específica para ser usado como una medida real de la biomasa, muchas agencias han descubierto que el índice es útil como una medida relativa para fines de monitoreo. Por ejemplo, los programas Sistema Africano de Información en Tiempo Real (ARTEMIS) de la Organización de Alimentación y Agricultura (FAO) de las Naciones Unidas, y el Sistema de Alerta Temprana sobre el Hambre (FEWS) del USAID, usan imágenes NDVI de escala continental derivadas del sistema NOAA-AVHRR para elaborar imágenes con el índice de vegetación para todo el continente africano cada diez días.<sup>10</sup>

Mientras la medida del NDVI ha demostrado ser útil en una variedad de contextos, un gran número de índices alternativos han sido propuestos para tratar con medioambientes especiales, como tierras áridas. IDRISI ofrece una amplia variedad de estos índices (más de 20 en los módulos VEGINDEX y TASSCAP combinados). El capítulo sobre los Índices de Vegetación ofrece una discusión detallada de sus características y aplicación potencial.

## **Análisis de los Componentes Principales**

El Análisis de los Componentes Principales (PCA) es una técnica de transformación lineal relacionada con el Análisis de Factores. Dado un juego de bandas de imágenes, el PCA produce un nuevo juego de imágenes, conocidas como componentes, no relacionadas entre sí y ordenadas en términos de la cantidad de discordancias que presentan con el juego de bandas originales.

El PCA ha sido tradicionalmente usado en la percepción remota como medio de compactación de datos. Para un juego típico de bandas de imágenes multiespectrales, es común encontrar que los dos o tres primeros componentes son capaces de constituir virtualmente toda la variabilidad original en los valores de reflexión. Los demás componentes tienden a estar dominados por los efectos del ruido. Al rechazar estos últimos componentes, el volumen de datos se reduce sin una pérdida de información perceptible.

Dado que los demás componentes están dominados por el ruido, de igual forma es posible usar el PCA como una técnica para eliminar el ruido. La producción del módulo PCA en IDRISI incluye los coeficientes de ambas transformaciones, en avance y en reversa. Al ajustar los coeficientes de los componentes del ruido en cero en la transformación reversa, se puede producir una nueva versión de las bandas originales con los elementos de este ruido ya removidos.

Recientemente, el PCS también ha demostrado tener una aplicación especial en el monitoreo ambiental. En los casos en que las imágenes multiespectrales están disponibles para dos fechas, las bandas de ambas imágenes son enviadas a un PCA como si todas viniesen de la misma imagen. En estos casos, los cambios entre las dos fechas tienden a aparecer en el resto de los componentes. Aún más, si una serie de tiempo de imágenes NDVI (o un índice de única banda similar) es enviada al análisis, puede lograrse un análisis muy detallado de los cambios y las tendencias ambientales. En este caso, el primer componente mostrará el típico NDVI sobre la serie entera, mientras que cada

<sup>10</sup> Un grupo de datos de archivo de imágenes NDVI mensuales para África se encuentra disponible en CD en Clark Labs. El cd de datos NDVI de África contiene: imágenes NDVI mensuales compuestas con los valores máximos (1982-1999), desviaciones promedio y estándar de imágenes NDVI mensuales por cada mes de un mismo período de tiempo, imágenes NDVI mensuales con anomalías, y datos auxiliares (DEM, uso de la tierra y cubierta terrestre, límites del territorio nacional y costas) para África en formato IDRISI. Para más información, comuníquese con Clark Labs.



componente subsiguiente ilustrará los cambios en una secuencia ordenada por grado de importancia. Al examinar estas imágenes, junto con los gráficos de su correlación con las bandas individuales en la serie original, pueden lograrse observaciones importantes sobre la naturaleza de los cambios y tendencias en la serie de tiempo. El módulo TSA (Análisis de la Serie de Tiempo) de IDRISI es una versión del PCA especialmente confeccionada para facilitar este proceso.

### **Otras Transformaciones**

Como se mencionó anteriormente, IDRISI ofrece una variedad de otras transformaciones. Éstas incluyen: transformaciones espaciales del color (COLSPACE), cálculos de la textura (TEXTURE), transformaciones termales de cuerpos oscuros (TERMAL) y una amplia variedad de transformaciones ad hoc que pueden lograrse más efectivamente con el utilitario Calculadora de Imágenes.

### **Conclusiones**

Los datos de sensores remotos son importantes para una amplia gama de disciplinas. Esto seguirá ocurriendo y probablemente aumente esta importancia gracias a la mayor disponibilidad de datos prometida por un creciente número de sistemas operacionales. La disponibilidad de estos datos, junto con el software informático necesario para analizarlos, brinda oportunidades que eran desconocidas sólo unas pocas décadas atrás. Estas oportunidades son interesantes particularmente para los profesionales y planificadores del medio ambiente involucrados en las áreas de la cartografía sobre los usos del suelo y la detección de cambios.

La estructura raster inherente de los datos captados por sensores remotos los hace compatibles con los SIG raster. Entonces, mientras IDRISI ofrece una amplia gama de herramientas para el procesamiento de imágenes, éstas son integradas por completo al juego mayor de herramientas del SIG raster que brinda el sistema.

# CAPÍTULO 4 - Panorama General del Sistema Idrisi

IDRISI consiste en un programa principal de interfase (con un menú y un sistema de barra de herramientas) y en una colección de más de 200 *módulos* de programa que proveen utilidades para la entrada, visualización y análisis de datos geográficos y de sensores remotos. Estos datos geográficos se describen en forma de *capas de mapas o capas temáticas* – componentes elementales de mapas que describen un solo tema. Como ejemplos de capas de mapas pueden incluir una capa de caminos, una capa de elevaciones, una con los tipos de suelo, una capa de reflectividad captada por sensores remotos, etc. Todos los análisis actúan sobre capas temáticas. Para la visualización, una serie de capas temáticas puede juntarse en una *composición cartográfica*.

Debido a que los datos geográficos pueden ser de distintos tipos, IDRISI incorpora las dos formas básicas de capas temáticas: *capas de imágenes raster y de imágenes vectoriales*.<sup>11</sup> Aunque IDRISI sea adepto a la entrada y visualización de las imágenes y capas vectoriales, el análisis está principalmente orientado hacia el uso de las capas de imágenes. Además, IDRISI ofrece un sistema completo de procesamiento de imágenes para los datos de imágenes captados por sensores remotos. Como resultado, éste es comúnmente descrito como un sistema raster. Sin embargo, IDRISI sí ofrece fuertes capacidades para el análisis de datos de atributos vectoriales, así como también rápidas capacidades de conversión de vector a *raster*. Entonces, el sistema brinda un poderoso juego de herramientas para el análisis geográfico que requieren ambos tipos de capas temáticas.

## Funcionamiento del Sistema

### La Ventana de Aplicaciones de IDRISI

Cuando se abre IDRISI, la ventana de aplicaciones ocupa toda la pantalla (en terminología Windows, ésta es automáticamente maximizada). Aunque no sea requerido, se recomienda mantenerla maximizada porque muchas de las ventanas de diálogo e imágenes que Ud. visualizará necesitarán una cantidad de espacio sustancial para la visualización.<sup>12</sup> La ventana de aplicaciones de IDRISI incluye el menú, la barra de herramientas y la barra de estado.

### El Sistema Menú

El sistema menú se encuentra en la parte superior de la ventana de aplicaciones. Puede activarlo con el mouse o bien presionando la tecla ALT y la tecla subrayada de la entrada del menú principal. Luego puede usar el mouse o las teclas de las flechas para moverse.

Si selecciona una opción del menú que incluye una flecha que apunta hacia la derecha, aparecerá un submenú. Al clicar sobre una opción del menú sin una flecha que apunte hacia la derecha, aparecerá una ventana de diálogo para ese módulo.

### La Barra de Herramientas

Justo por debajo del menú, hay un juego de botones que se llama barra de herramientas. Cada botón representa un módulo de programa o bien una operación interactiva que puede seleccionarse clickeando sobre el botón con el mouse.

Algunos de estos botones pueden quedar en estado activo o inactivo. Cuando están activos, los botones aparecen como presionados luego de ser clickeados. En estos casos, los botones se desactivan al clickear de nuevo sobre los mismos.

También podrá observar que algunos botones no están siempre disponibles para ser usados. Esto se indica con el icono del botón en color gris. Apoye el cursor sobre un icono para que el nombre de la función o del módulo representado por el icono aparezca momentáneamente. El juego de iconos representa funciones de visualización interactiva, como también algunos de los módulos más usados.

---

<sup>11</sup> Para una discusión con detalle sobre la estructura raster y vectorial, vea el capítulo **Introducción al SIG** en este volumen.

<sup>12</sup> Por esta razón, recomendamos que la barra de tareas del sistema operativo esté en "ocultar automáticamente" para que no ocupe constantemente mucho espacio de la pantalla. Para hacer esto, vaya a Inicio/Configuración/Barra de Tareas y presione la opción ocultar automáticamente.



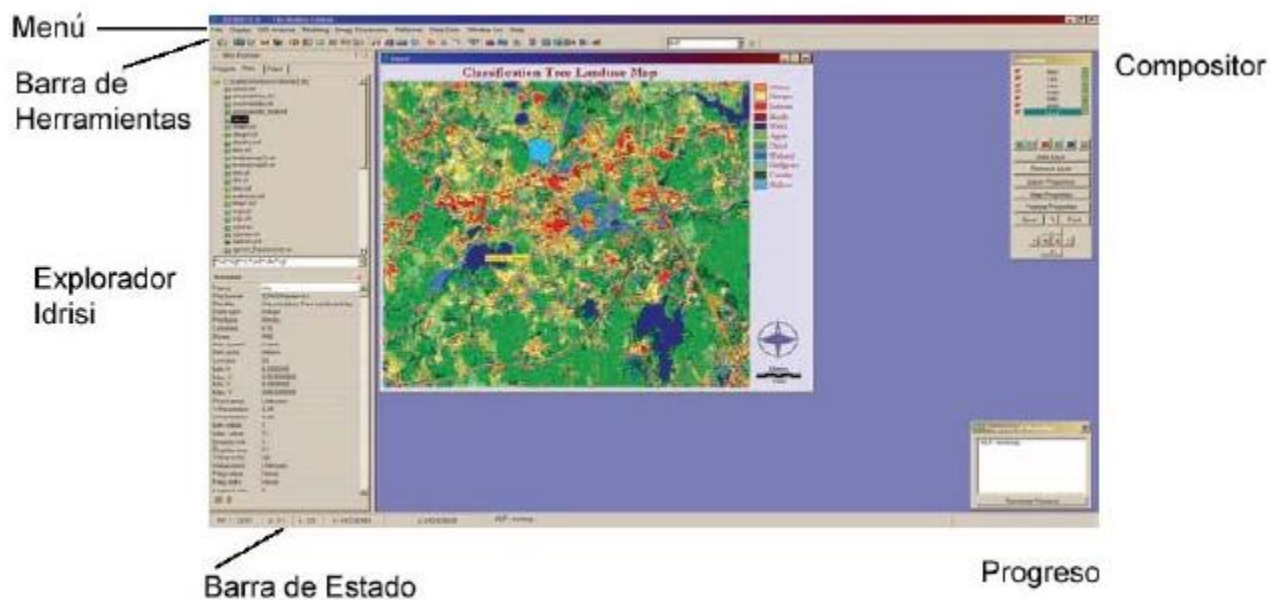


Figura 4-1

## La Barra de Estado

En la parte inferior de la pantalla se encuentra la barra de estado. Ésta ofrece una variedad de información acerca de la funcionalidad del programa.

Cuando los mapas y las capas de éstos se muestran en la pantalla y el mouse se mueva sobre una de estas ventanas, la barra de estado indicará la posición del cursor dentro del mapa en las coordenadas de fila y columna de la imagen y las coordenadas X e Y del sistema de referencia cartográfico. Además, la barra de estado indica la escala de la representación en la pantalla como una *Fracción Representativa* (Representative Fraction-RF).<sup>13</sup>

La barra de estado también indicará el progreso de la operación analítica más reciente con una barra de progreso gráfico, así como también una medida del porcentaje realizado. Debido a que IDRISI ha sido diseñado para permitir operaciones con tareas simultáneas, es posible que más de una operación esté trabajando simultáneamente. Para ver la lista de todos los procesos activos y sus estados, simplemente haga doble clics sobre el panel de la barra de progreso, en la parte inferior derecha de la pantalla. Los módulos también pueden finalizarse desde aquí.

## Módulos del Programa

A los módulos del programa se puede acceder de tres formas:

1. seleccionando el módulo en la estructura del menú y activándolo con un clic del mouse,
2. seleccionando su icono de programa en la barra de herramientas, justo debajo del menú, y
3. tipeando o seleccionando el nombre del módulo de la lista alfabética que ofrece la utilidad Acceso Directo (Short Cut).

Cada uno de estos métodos activa una ventana de diálogo para ese módulo. Luego de ingresar la información necesaria para la operación a realizarse y de clicar el botón OK (Aceptar), empezará a funcionar el módulo del programa.

<sup>13</sup>Una Fracción Representativa expresa la escala de un mapa como una proporción fraccional. Entonces, una RF de 1/10.000 indica que cada unidad gráfica de la imagen de la pantalla es una diezmilésima del tamaño real. Idrisi determina automáticamente la resolución y las dimensiones de su pantalla, los cuales en combinación con la mínima y la máxima de las coordenadas x y de la imagen o de la capa vectorial, se usan para determinar la RF para cualquier ventana de visualización.

## Rutas de Datos y Proyectos

Los módulos del programa funcionan sobre datos – capas de mapas y datos tabulares almacenados en los archivos de datos. Estos archivos son guardados en carpetas (también llamadas directorios o folders) y subcarpetas (subdirectorios) en forma de drives en la computadora. La ubicación de cualquier archivo de datos específico es designada por un nombre que consiste en el nombre del archivo más el drive, la ubicación de las carpetas y de las subcarpetas. Conjuntamente, esto se conoce como Ruta de los datos (ya que especifica la ruta hacia una colección particular de datos). Por ejemplo, "c:\massachusetts\middlesex\census\_tracts.vct" puede designar una capa vectorial de las regiones cubiertas por un censo contenidas en la subcarpeta Condado de Middlesex de la carpeta Massachussets en el drive del disco duro C.

IDRISI puede trabajar con archivos de cualquier Ruta de datos (incluyendo rutas de redes). Sin embargo, a menudo, tener que especificar los nombres de carpetas y subcarpetas constantemente puede resultar una molestia, particularmente cuando un proyecto específico generalmente necesita acceder a datos en un juego limitado de carpetas. Para simplificar el problema, IDRISI permite especificar estas rutas de datos como pertenecientes a un proyecto específico. Cuando las rutas hacia estas carpetas son designadas en un Archivo de Proyecto (Project File), IDRISI encuentra los datos con mucha facilidad y una mínima intervención del usuario.

### La Carpeta de Trabajo del Proyecto

Dentro de cualquier Archivo de Proyecto, la carpeta más importante es la *Carpeta de Trabajo* (Working Folder). Los usuarios pueden elegir almacenar todos los datos para un proyecto en una Carpeta de Trabajo (particularmente para proyectos menores). En cambio, para proyectos más grandes, o proyectos que requieren bibliotecas de juegos de datos cuidadosamente organizados y protegidos, se pueden agregar al Archivo de Proyecto *Carpetas de Recursos* (Resource Folders) adicionales.

Mientras el usuario siempre puede especificar cualquier ubicación para los datos de entrada y de salida, designar las carpetas más comúnmente usadas en un Archivo de Proyecto facilita el uso de IDRISI. Por ejemplo, si los nombres de los datos de entrada se asignan sin una ruta, IDRISI automáticamente mira primero en la Carpeta de Trabajo, luego en cada Carpeta de Recursos para encontrar el archivo. De manera similar, si no se especifica una ruta alternativa, los datos de salida son automáticamente ubicados en la Carpeta de Trabajo.

### Carpetas de Recursos del Proyecto

Las Carpetas de Recursos contienen los datos a los que puede accederse rápidamente a través de la lista de selección de IDRISI (ver abajo). Un Archivo de Proyecto puede contener cualquier número de Carpetas de Recursos. Para el usuario, la Carpeta de Trabajo y todas las Carpetas de Recursos funcionan como una sola carpeta de proyectos. Por ejemplo, uno puede pedirle a IDRISI que visualice una capa cartográfica raster llamada “usos del suelo”. Si no se suministró ninguna carpeta de información, IDRISI busca primero el archivo en la Carpeta de Trabajo, luego en cada Carpeta de Recursos, y visualiza la primera instancia que encuentra. Esto es muy conveniente ya que le permite al usuario ingresar nombres de archivos sin sus rutas. Sin embargo, si existen nombres de archivos duplicados en carpetas separadas que son parte del mismo proyecto, el usuario debe tener precaución y recordar el orden en el que IDRISI accede a las carpetas del proyecto.

### Estableciendo las Rutas de los Datos

Las rutas de los datos para las Carpetas de Trabajo y de Recursos pueden establecerse en la opción Data Paths (Rutas de Datos) del menú Archivo (File menú). Ud. también puede hacer esto cliqueando el primer icono desde la izquierda de la barra de herramientas para acceder al diálogo Project Environment.

## Trabajando con los Cuadros Diálogo de IDRISI

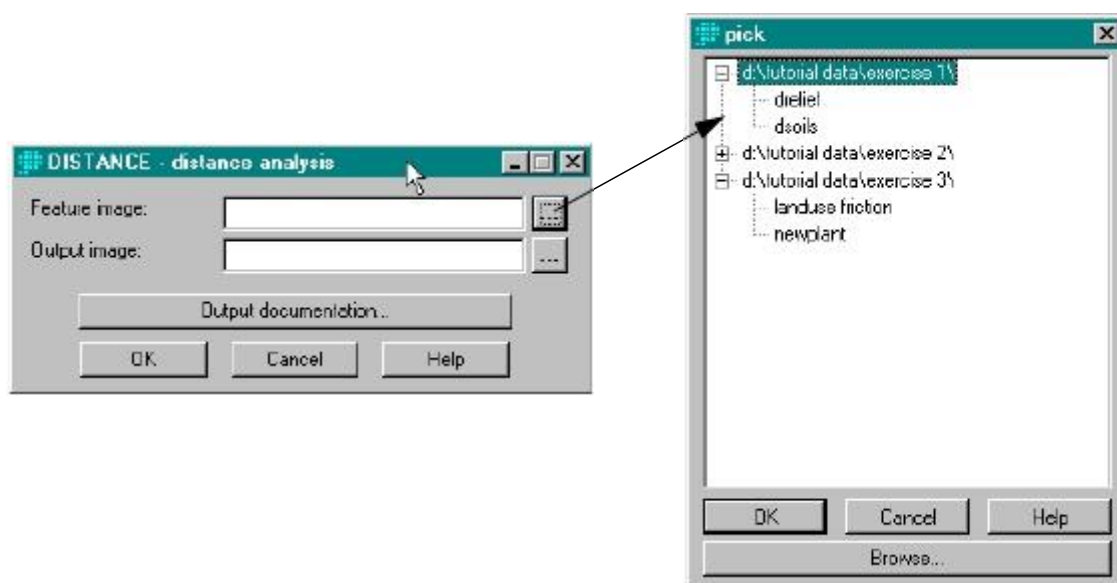
Cuando se activa cualquier módulo, aparece un cuadro de diálogo con información sobre los datos u opciones de selección que se necesitan para que el módulo funcione. Virtualmente, todos los cuadros de diálogo deben llenarse con información antes de que el módulo funcione. Sólo los cuadros de diálogo de entrada del título y de las unidades de medida que se encuentran en el botón Documentación de Salida (Output Documentation) pueden dejarse en blanco (Se recomienda, sin embargo, llenar también estos cuadros.) En algunos casos, los cuadros de entrada ya contienen valores, o se llenarán con valores mientras se ingresa otra información. Éstos son valores que en informática se designan “por defecto” (que aparecen siempre automáticamente) y que pueden editarse con libertad. En casos donde debe elegirse un juego de opciones, las configuraciones más comunes son normalmente preseleccionadas. Éstas deben ser examinadas y cambiadas, de ser necesario. El sistema mostrará un mensaje de error en los casos en que se haya dejado afuera un elemento de datos necesario.

## Listas de Selección

Siempre que un cuadro de diálogo requiere el nombre de un archivo de datos de entrada (como una imagen raster), Ud. tiene dos opciones para la entrada de ese valor. La primera es simplemente tipear el nombre en el cuadro de entrada.

Alternativamente, Ud. puede activar una *lista de selección* de opciones al hacer doble clic en el cuadro de entrada, o al clicar el *botón de la lista de selección* ubicado a la derecha del cuadro de entrada (el botón pequeño con los caracteres elípticos "..."). La lista de selección está organizada en un directorio en forma de árbol con todos los archivos del tipo requerido existentes en las Carpetas de Trabajo y de Recursos. La Carpeta de Trabajo siempre se encuentra en la parte superior de la lista, seguida por cada Carpeta de Recursos en el orden en el que están listadas en el Project Environment. Los archivos que se muestran en la lista de selección dependen del cuadro de entrada particular desde el cual fue lanzada la lista de selección. Todos los archivos de tipo IDRISI están diseñados por extensiones únicas de nombres de archivo. Si un cuadro de entrada requiere una imagen raster, por ejemplo, la lista de selección lanzada desde ese cuadro de entrada sólo mostrará esos archivos que tengan la extensión ".rst".

Se puede seleccionar un archivo de la lista marcándolo con el botón izquierdo del mouse, y luego seleccionarlo haciendo clic en el botón OK o presionando la tecla Enter. Alternativamente, un archivo también puede seleccionarse haciendo doble clic sobre su nombre. Luego, la lista de selección desaparecerá, y el nombre de ese archivo aparecerá en el cuadro de entrada. Observe que Ud. también puede elegir un archivo que no se encuentra en el proyecto activo haciendo clic en el botón Browse (Buscar) en la parte inferior de la lista de selección.



## Nombres de Archivos de Salida

Normalmente, a los archivos les deberá dar nombres que tengan significado para Ud. Es común generar muchos archivos de salida en un solo análisis. Los nombres de archivos descriptivos son de ayuda para mantener un seguimiento de estos archivos.<sup>14</sup> Los nombres de archivos pueden ser largos y pueden contener espacios en blanco y la mayoría de los caracteres del teclado (todos excepto / \ : \* ? " < > y |). No es necesario que el usuario especifique la extensión de tres letras del nombre del archivo ya que IDRISI se ocupa de esto. Puede ingresarse una ruta completa en el cuadro del nombre de archivo de salida. Si no se ingresa una ruta, el archivo de salida se escribirá automáticamente en la carpeta de trabajo que se especifica en el proyecto activo.

Al hacer clic en el botón de la lista de selección ubicado a la derecha del cuadro del nombre de archivo de salida se abrirá un cuadro de diálogo Windows de tipo estándar para Guardar Como (Save As). Aquí, el usuario puede seleccionar cualquier carpeta para el archivo de salida y puede ingresar el nombre del archivo. Cuando se usa el botón de la lista de selección, se ingresará por defecto un nombre de archivo de salida automáticamente generado. Para cambiar este nombre, simplemente cliquee en el cuadro de nombre de archivo y tipee el nombre deseado.

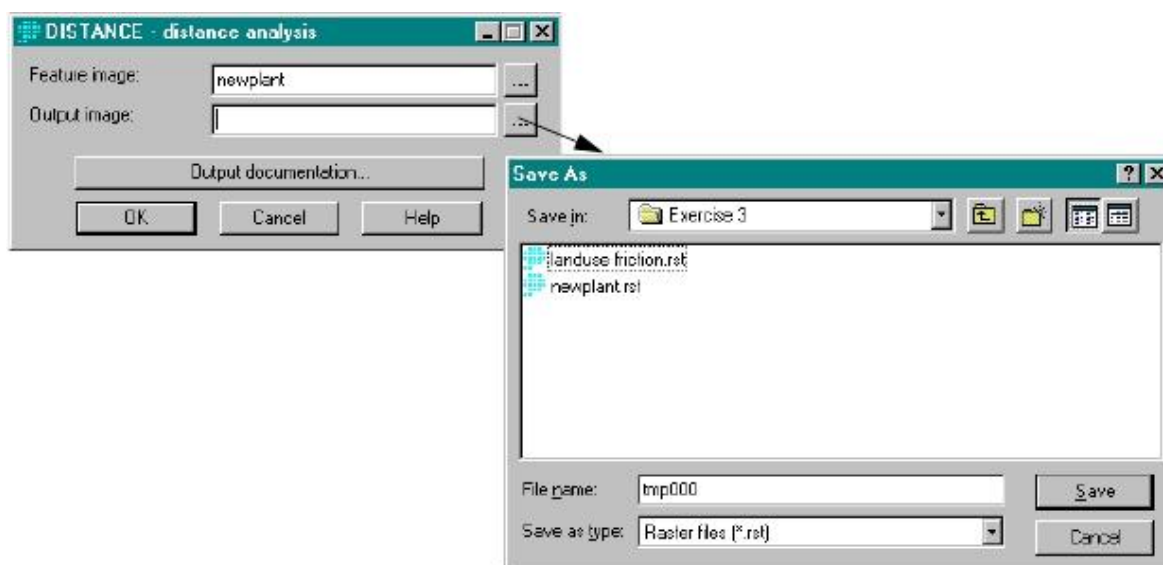
<sup>14</sup> El archivo de documentación para archivos de salida de datos raster y vectoriales incluye en el campo lineage la sintaxis desde la cual se creó la capa. Esto puede verse con la función Metadata.

Como se dijo anteriormente, los usuarios por lo general le dan nombres descriptivos a los archivos para ayudar a evitar la confusión a medida que la base de datos crece. Sin embargo, IDRISI puede generar nombres automáticos para los archivos de datos de salida. Los nombres automáticos de salida se utilizan para el nombramiento rápido de archivos temporarios.

Los nombres automáticos de los archivos de salida comienzan con un prefijo de tres letras definido por el usuario (establecido en TMP por defecto),<sup>15</sup> seguido por un número de tres dígitos. Por defecto, los nombres de archivo comienzan con TMP001 y llegan hasta TMP999. Como estos archivos son por lo general temporarios, la protección contra escritura (ver abajo) es desactivada para los archivos con nombres que comienzan con el prefijo designado seguido por tres dígitos. Observe que luego de salir de IDRISI, el ciclo comenzará nuevamente desde TMP001 la próxima vez que se use IDRISI. Debido a que la secuencia de numeración comienza desde 001 en cada nueva sesión, es probable que los datos de esos archivos se pierdan en una sesión siguiente, a menos que se guarden intencionalmente con un nombre nuevo.

Para usar la función de nombre automático, vaya al cuadro de nombre del archivo de salida en cuestión, y haga doble clic en el cuadro o cliquee el botón de la lista de selección. Si se usa el doble clic, se generará un nombre de archivo automático y se colocará en el cuadro de nombre del archivo de salida. Debido a que no se especifica ninguna ruta con este método, la producción irá automáticamente a la Carpeta de Trabajo.

En el caso en que se cliquee el botón de selección al lado de un cuadro de nombre del archivo de salida, aparecerá un cuadro de diálogo Guardar Como de Windows con el nombre temporario ya seleccionado (Ej.: TMP001).



## Protección contra Escritura

Por defecto, IDRISI controla si el archivo de salida dado ya existe. Si es así, éste preguntará si desea sobrescribirlo. De lo contrario, Ud. será llevado de nuevo al cuadro de diálogo donde puede ingresar un nombre diferente.

Hay tres excepciones a esta lógica. La primera es cuando se genera un nombre de salida automático (ver la sección inmediatamente anterior). La segunda es cuando el usuario elimina la protección contra escritura en el diálogo User Preferences (Preferencias del Usuario) en el menú Archivo. Y la tercera ocurre cuando los módulos se ejecutan en modo macro.

## Cómo Buscar Ayuda

Mientras se usa IDRISI, la Ayuda está siempre a disposición. IDRISI contiene un extenso Sistema de Ayuda on-line (Help System) al que se puede acceder en una variedad de formas. El medio más común de acceder a la ayuda es seleccionarla del menú principal de IDRISI. Sin embargo, cada módulo del programa también contiene un botón de ayuda. En este caso, la ayuda es sensible al contexto, y accede a la sección de Ayuda asociada con ese módulo en particular. En cualquier caso, vale la pena familiarizarse con todas las opciones que brinda el Sistema de Ayuda. Para realizar esto, seleccione la opción Using Help (Usando la Ayuda) del menú principal de Ayuda.

<sup>15</sup>El prefijo del archivo de salida generado automáticamente puede cambiarse en la opción User Preferences (Preferencias del Usuario) del menú Archivo.

# CAPÍTULO 5 - Capas de Mapas, Archivos del Grupo Raster, Colecciones Vectoriales y Estructura de los Datos

## Capas de Mapas o Capas Temáticas

Las capas temáticas son las unidades fundamentales de visualización y análisis en el SIG. Una capa temática es un tema elemental, un fenómeno simple que puede ser plasmado sobre un mapa a través del espacio. Ejemplos de esto incluyen una capa del uso del suelo, una capa de elevación, una capa con los suelos, etc. Las capas temáticas entonces, son, de alguna manera, diferentes a los mapas tradicionales. Estos últimos usualmente consisten en varias capas temáticas. Por ejemplo, una hoja de mapa topográfico generalmente consiste en una capa de contornos, una con la cubierta boscosa, una capa de administración de fronteras, una capa de caminos y una de asentamientos. En IDRISI se aplica este mismo concepto. Un *mapa* es una representación gráfica del espacio compuesta por una o más *capas* temáticas, usando una herramienta llamada *Composer* (Diseñador).

Esta desagregación del mapa en sus constituyentes elementales ofrece ventajas importantes. Claramente, permite la producción de mapas altamente personalizados; simplemente ponemos juntas las capas que deseamos que estén juntas. Sin embargo, la razón más importante para almacenar datos en esta forma es que las capas son las variables básicas usadas por el SIG en la modelación analítica. Entonces, por ejemplo, podemos crear un mapa de la erosión del suelo como una función matemática del tipo de suelo, inclinación, cubierta terrestre y capas de precipitaciones. Más aún, la desagregación de los datos geográficos en capas permite producir una gama extraordinaria de modelos matemáticos y lógicos.

## Tipos de Capas de Mapas

Como se detalla en el capítulo Introducción al SIG, existen dos tipos básicos de capas en el SIG: capas de imágenes raster y de imágenes vectoriales.<sup>16</sup> Algunos sistemas usan exclusivamente uno u otro tipo. IDRISI incorpora ambos tipos, ya que cada uno posee ventajas especiales. En cambio, mientras tienen el mismo nivel en términos de visualización y consultas tradicionales sobre las bases de datos, IDRISI ofrece un rango mucho más amplio de operaciones analíticas para las capas raster. Esto se debe en parte al desarrollo histórico de IDRISI desde un sistema casi puramente raster, y en parte porque la gama de operaciones analíticas posibles en SIG es mucho mayor con capas raster (como resultado de su simplicidad y su predecible regularidad).

Todas las capas raster de IDRISI tienen la misma estructura básica. Los subtipos solamente existen en términos del tipo de los datos numéricos usados para almacenar los valores de las celdas. Como uno puede imaginar fácilmente, las imágenes raster poseen un gran volumen de datos. Entonces, los cambios pequeños en el tipo de datos subyacentes pueden equivaler a diferencias enormes en los requerimientos para ser almacenados. IDRISI es compatible con imágenes raster almacenadas con números bytes, enteros y reales, así como también en dos formatos especiales para el almacenamiento de imágenes a todo color.

Las capas vectoriales describen la ubicación y la naturaleza de las distintas características geográficas. Los subtipos incluyen capas de Puntos (Point), Líneas (Line), Polígonos (Polygon) y Textos (Text). Las capas de puntos son un fenómeno que puede describirse por un solo punto, tal como datos meteorológicos o (en escalas pequeñas) ubicaciones de ciudades. Como lo indica el nombre, las capas vectoriales de líneas describen características lineales como ríos y caminos. El término *polígono* puede que sea menos familiar. Los polígonos representan áreas. Debido a que los bordes de las áreas están hechos de segmentos de líneas rectas entre puntos, la figura formada es técnicamente un polígono. El término *polígono* ha empezado entonces a formar parte de la terminología del SIG. Finalmente, las capas de textos se utilizan para describir la ubicación y orientación de los nombres de los textos.

## Nombres de las Capas de Mapas o Capas Temáticas

Todos los módulos analíticos en IDRISI funcionan sobre capas temáticas. Entonces, los nombres de los archivos de

---

<sup>16</sup>En IDRISI, los términos capa raster, capa de imagen raster e imagen se usan de manera indistinta.

entrada y de salida que se dan en las operaciones de IDRISI son por lo general aquellos de las capas temáticas. En el uso normal de IDRISI, las capas temáticas son especificadas con nombres simples que no necesitan expresar su ruta de datos (el Project Environment de IDRISI define las rutas hacia las carpetas de trabajo y de recursos). Tampoco es necesario especificar las extensiones de los nombres de sus archivos (ya que IDRISI busca y crea extensiones específicas automáticamente).

Al ser consistentes con las variantes de 32 bits del sistema operativo Windows, los nombres de las capas pueden contener cualquier letra del alfabeto y también numerales, espacios en blanco y la mayoría de los símbolos (excluyendo \ / : \* ? " < > y |). Por ejemplo, las capas pueden tener nombres como “suelos” o “usos del terreno 1996”. En principio, los nombres de archivo pueden tener un largo de hasta 255 caracteres. Sin embargo, en la práctica, se recomienda que solo tengan el largo necesario para que todo el nombre del archivo se vea en las listas de selección y los cuadros de diálogo de entrada.

En un uso normal, no se hace distinción entre los nombres de imágenes y de capas vectoriales. No obstante, su tipo siempre es reconocido por el sistema – por el contexto en el que fueron creadas y por la extensión del archivo que el sistema usa internamente para almacenar cada capa. Entonces, una capa de imagen raster llamada “suelos” será guardada como “suelos.rst” internamente, mientras que una capa vectorial llamada “suelos” será guardada como “suelos.vct”. Como resultado, es posible tener capas vectoriales y raster con el mismo nombre. Sin embargo, la mayoría de los usuarios de IDRISI sólo usan esta opción en casos donde los dos archivos almacenan manifestaciones vectoriales y de imágenes de los mismos datos subyacentes.

Cuando los nombres de archivos se ingresan en los cuadros de diálogo de IDRISI, el sistema siempre reconoce el tipo de capa apropiado en uso. Es más, sólo se verán en la lista de selección aquellos archivos del tipo apropiado para esa operación.

## Archivos de Datos de Capas de Mapas

Mientras que nos referimos a una capa cartográfica con un nombre simple, en realidad ésta es guardada por IDRISI como un par de archivos de datos. Uno contiene los datos espaciales, y el segundo contiene información acerca de dichos datos (es decir, documentación o *metadata*). Entonces, mientras que las imágenes raster son almacenadas en archivos de datos con extensión “.rst”, cada una está acompañada por un archivo de documentación con extensión “.rdc” (es decir, documentación raster). De manera similar, los archivos de datos vectoriales tienen extensión “.vct”, cada uno está acompañado por un archivo de documentación con extensión “.vdc” (es decir, documentación vectorial). En el uso, en cambio, Ud. se referirá a estas capas con sus simples nombres de capas (es decir, “suelos” y “distritos”, respectivamente).

Los contenidos de los archivos de documentación de datos son descritos en detalle más adelante en la sección sobre las estructuras de archivo.

## Colecciones de Capas Vectoriales

Algunas veces tiene sentido agrupar capas de mapas en colecciones. Un buen ejemplo es cuando Ud. tiene un grupo de características vectoriales asociadas con una tabla de datos. Por ejemplo, un archivo vectorial puede ser creado a partir de las regiones cubiertas por un censo dentro de una ciudad. Cada una de estas regiones posee múltiples atributos como ingresos medios, densidad poblacional, alcance educacional medio, etc. Cada uno de estos atributos puede unirse a un archivo vectorial y así, definir la geografía de las regiones cubiertas por un censo y visualizarlas como una capa de mapa. En tal caso, la combinación del archivo vectorial con toda la tabla de la base de datos constituye una colección de capas de mapas.

Una colección vectorial producida por el enlace de un archivo vectorial geográfico o de definición de características (como la representación digital de las regiones cubiertas por un censo mencionadas anteriormente) con una tabla de base de datos.<sup>17</sup> Ésta se llama colección de tablas unidas y se establece con un archivo de enlace vectorial (.vlx) y se crea en el Taller de Bases de Datos. Todos los elementos de la colección deben encontrarse en la misma carpeta. Los archivos de enlace vectorial (.vlx) asocian un archivo vectorial de definición de características con una tabla de base de datos. Como consecuencia, cada uno de los campos (columnas) de datos en la tabla de datos se convierte en una capa, y el grupo completo de campos produce una colección de tablas unidas o relacionadas. Como se podrá observar, IDRISI posee características especiales para la visualización y el análisis de las relaciones entre las capas

---

<sup>17</sup>Los archivos de definición de características y los archivos de imagen describen la geografía de sus características pero no sus atributos. En cambio, las características poseen valores de los identificadores usados para asociar los atributos almacenados en tablas de bases de datos o en archivos de valores de los atributos.

de una colección semejante. Todo lo que se necesita es un archivo de enlace que pueda establecer las cuatro propiedades importantes de una colección:

1. el archivo vectorial de definición de características (es decir, marco espacial);
2. una base de datos de atributo asociada;
3. una tabla específica dentro de esa base de datos; y
4. el campo de la base de datos que contiene los identificadores que pueden asociar los registros de la base de datos con las características vectoriales (el campo de enlace).

En el Taller de Bases de Datos, la herramienta Establish Display Link (Establecer Enlace de Visualización) se usa para construir estos archivos de enlace. Sólo las capas de puntos vectoriales, de líneas y de polígonos pueden ser especificadas como un archivo vectorial de definición de características. Los archivos de la base de datos y las tablas asociadas deben ser archivos Microsoft Access Database Engine con extensión “.mdb”.

## Capa Grupal Raster

Un grupo de capas raster independientes puede ser asociado con un archivo grupal raster (.rgf). Como lo indica el nombre, un archivo de grupo es simplemente una lista de un grupo de capas independientes que uno desea asociar o ligar. Por ejemplo, un archivo grupal puede consistir de las siete bandas de imagen que arman una imagen del satélite Landsat.

Muchos de los pasos del procesamiento de imágenes en el IDRISI le permiten especificar un archivo grupal como entrada en lugar de usar cada banda individualmente. Esto ahorra mucho tiempo cuando el mismo grupo de imágenes se usa en varios procedimientos. No obstante, existen razones más imperativas para crear archivos grupales que su utilización como simple medio para especificar colecciones de archivos.

1. Cuando se muestra más de un miembro de un grupo en la pantalla, Ud. tiene la opción de tratarlos por igual durante las operaciones de zoom (magnificación) y pan (seguimiento). Entonces, cuando a un miembro se le aplica la magnificación o seguimiento, a todos los demás miembros de ese grupo que se encuentran en la pantalla se les aplicará lo mismo simultáneamente.
2. Cuando la opción *feature properties* (propiedades de las características) es activada, las consultas acerca de los valores de los datos para una capa específica producirán una tabla (u opcionalmente, un gráfico) de los valores para todos los atributos en la colección en esa ubicación.

El Explorer (Explorador) de IDRISI, en la barra de herramientas (toolbar) o del menú Archivo (File) puede usarse para facilitar la creación de archivos grupales. Observe que hay además una variante especial de un archivo grupal conocido como archivo de *series de tiempo* usado para el análisis de series de tiempo. Los archivos de firmas usados en la clasificación de imágenes también pueden ser colocados juntos en *archivos grupales de firmas* y *archivos grupales de firmas hiperspectrales*. Estos archivos de grupo también son creados con IDRISI Explorer.

## Archivos Grupales

El segundo tipo de colección es un archivo grupal raster. Como lo indica el nombre, un archivo grupal es simplemente una lista de un grupo de capas independientes que uno desea asociar o ligar. Por ejemplo, un archivo grupal puede tener las siete bandas de imagen que arman una imagen satelital LANDSAT. Muchos de los pasos del procesamiento de imágenes en IDRISI le permiten especificar un archivo grupal como entrada en lugar de usar cada banda individualmente. Esto ahorra mucho tiempo cuando el mismo grupo de imágenes se usa en varios procedimientos. No obstante, existen razones más imperativas para crear archivos grupales que su utilización como simple medio para especificar colecciones de archivos.

1. Cuando se muestra más de un miembro de un grupo en la pantalla, Ud. tiene la opción de tratarlos por igual durante las operaciones de zoom (aproximación) y paneo (seguimiento). Entonces, cuando a un miembro se le aplica el zoom o paneo, a todos los demás miembros de ese grupo que se encuentran en la pantalla se les aplicará lo mismo simultáneamente.
2. Cuando la opción *propiedades de las características* es activada, las consultas acerca de los valores de los datos para una capa específica producirán una tabla (u opcionalmente, un gráfico) de los valores para todos los atributos en la colección en esa ubicación.



Nuevamente, el Editor de Colecciones (de la barra de herramientas o del menú Archivo) puede usarse para facilitar la creación de archivos grupales. Observe que hay además una variante especial de un archivo grupal conocida como archivo de *serie de tiempo* usado para el análisis de series de tiempo. Los archivos de firmas usados en la clasificación de imágenes también pueden ser colocados juntos en *archivos grupales de firmas y en archivos grupales de firmas hiperespectrales*.

## Convenciones para la Designación de los Elementos de las Colecciones

Para especificar una capa que pertenece a una colección, se usa la convención “dot” – es decir, la referencia es una combinación del nombre de la colección y del nombre de la capa, separados por un punto. Por ejemplo, supongamos que uno tuviese un archivo de enlace llamado CensusTractData99, que asocia un archivo vectorial de definición de característica con una tabla de base de datos de las estadísticas de un censo. Cada una de las capas en la colección sería referida por una combinación del nombre de la colección con el nombre del campo apropiado en la tabla. Entonces, la capa del Ingreso Medio sería referida como:

CensusTractData99.Ingreso Medio

De manera similar, uno puede crear un archivo grupal de las siete bandas multiespectrales de una imagen LANDSAT. Tal vez las bandas tienen nombres como OahuBand1, OahuBand2, etc. Si el archivo grupal creado para asociarlas se llama LANDSAT TM, entonces, una referencia a la segunda banda sería de la siguiente manera:

LANDSATTM.OahuBand2

## Listas de Selección para Archivos Grupales y Visualización de Colecciones

Las listas de selección construidas por IDRISI para facilitar la selección de los archivos de entrada tienen *conocimiento de la colección* (collection-aware). Por ejemplo, cuando se necesita una imagen raster, la lista de selección mostrará tanto archivos raster grupales como imágenes raster. Las colecciones son inmediatamente evidentes en una lista de selección por el símbolo “+” en su punto de conexión con el árbol del directorio. Si Ud. hace clic sobre el archivo de la colección, éste se expandirá para mostrar cada uno de los miembros o elementos incluidos. Estos miembros se muestran con sus nombres simples. No obstante, si se escoge uno, IDRISI ingresará su referencia completa (usando la convención dot) en el cuadro de entrada. En algunos casos, el nombre de un archivo grupal puede seleccionarse como entrada para un cuadro de diálogo.

## Archivos de Atributos

Un archivo de atributos contiene información acerca de las características de los detalles, pero no la definición geográfica de esos detalles. IDRISI trabaja con dos formas de archivos de atributos y archivos de valores ASCII.

### Tablas de Base de Datos

IDRISI incorpora el Motor de Bases de Datos Microsoft Access con su utilitario el Taller de Bases de Datos (Database Workshop). Por lo tanto, esta forma de archivos de atributos de IDRISI son tablas que poseen extensión “.mdb”, y pueden además ser usadas y modificadas con Microsoft Access o cualquier otro sistema compatible con Access. La colección de capas unidas solo puede crearse con este tipo de archivo de atributo. Los archivos Microsoft Access Database pueden contener múltiples tablas, cada una de las cuales puede unirse para formar una colección de capas. Para mayor información acerca del uso de las tablas de bases de datos con IDRISI, ver el capítulo **Taller sobre Bases de Datos**.

### Archivos de Valores

La segunda forma de archivo de atributo usado por IDRISI es un archivo de valores ASCII. Éste posee una estructura de archivo muy simple que contiene los valores para un solo atributo. Es almacenado en un formato de

texto ASCII y consiste en dos columnas de datos separadas por uno o más espacios. La primer columna contiene un identificador que puede usarse para asociar el valor con una característica (tanto raster como vectorial), mientras que la segunda contiene el valor del atributo. Los archivos con valores de atributo tienen una extensión “.avl”. Algunos módulos los crean como archivos de salida mientras que otros requieren (o son capaces de usar) estos archivos como entrada para análisis. Los archivos con valores de atributo pueden ser importados o exportados desde o hacia una tabla de base de datos usando el Taller sobre Bases de Datos. Además, IDRISI brinda un procedimiento (ASSIGN) para asignar esos valores a un grupo de características incluidas en una imagen raster o archivo vectorial, y un procedimiento acompañante (EXTRACT) para crear nuevos archivos de valores como un resumen estadístico de los valores en otra imagen, para los detalles de una imagen de definición de características.

## Estructura de los Archivos de las Capas de Mapas

### Capas Raster (.rst)

Las imágenes raster son el tipo de dato más importante y fundamental en IDRISI. El sistema les asigna automáticamente una extensión de archivo “.rst”. Las capas raster son simples en estructura y regulares en su organización, permitiendo una extraordinaria gama de operaciones analíticas. Las estructuras de los datos que IDRISI usa para almacenar las imágenes raster son optimizadas para obtener simplicidad y eficiencia.

Las imágenes raster definen una región de espacio rectangular por medio de una fina matriz de valores de datos numéricos que describen la condición o naturaleza del paisaje en cada celda de una fina grilla. Estos valores numéricos de las celdas de una grilla no solo se usan para análisis, sino también para la visualización. Al asignar colores específicos (en una *paleta*) a los rangos numéricos designados, se forma una imagen color del tipo de una matriz muy fina (tan fina que generalmente las celdas individuales no pueden verse sin un zoom a escala bastante grande).

En esta estructura de celdas de grilla usada por IDRISI, las filas y columnas son numeradas comenzando de cero. Por lo tanto, una imagen de 1000 columnas y 500 filas tiene columnas numeradas desde 0-999 y filas numeradas desde 0-499. A diferencia del sistema Cartesiano de coordenadas, la celda 0.0 se encuentra en la esquina superior izquierda. Las celdas están numeradas de izquierda a derecha, como es de esperarse, pero las filas están numeradas de arriba hacia abajo. Esto es común en la mayoría de los sistemas raster debido a la dirección de muchos dispositivos de salida, particularmente las impresoras, que imprimen de arriba hacia abajo.

Mientras que la estructura lógica de un archivo de imagen es una grilla, la estructura real, como es almacenada, es una sola columna de números. Por ejemplo, una imagen que consiste en 3 filas por 5 columnas es almacenada como una sola columna de 15 números. Es el archivo de documentación de la imagen lo que permite a los módulos de IDRISI reconstruir la grilla a partir de esta lista. Imagen que se muestra en forma de grilla:

10	15	9	10
1	14	10	11
14	13	11	10

posee un archivo de imagen que se parece a esto (si uno pudiera verlo):

```
10
15
9
10
1
14
10
11
14
13
11
10
```

El archivo raster de documentación, que contiene el número de filas y columnas, permite recrear la imagen correctamente para su visualización y análisis.

Como se dijo anteriormente, los subtipos más importantes de imágenes raster se diferencian basándose en los tipos de datos usados para representar los valores de las celdas. IDRISI reconoce cuatro tipos de datos: enteros, byte, reales y RGB24.

1. Los enteros son números que no poseen parte fraccional y se ubican dentro de un rango de -32768 a +32767. Las filas enteras a veces se llaman filas enteras de 16 bits, ya que necesitan 16 bits (es decir, 2 bytes) de memoria por valor (y por lo tanto, por pixel). Los valores enteros pueden ser usados para representar valores cuantitativos o como códigos para tipos de datos categóricos. Por ejemplo, un mapa de suelos puede almacenar tres tipos de suelo en una región particular. Como las imágenes de IDRISI son almacenadas en formato numérico, estos tipos pueden tomar códigos enteros 1, 2 y 3. El archivo de documentación guarda una leyenda para esto sobre la relación entre los códigos enteros y los tipos de suelo reales.
2. Los valores byte son números enteros positivos que van del 0 al 255. El tipo de datos byte es simplemente un subtipo de los enteros. Se utiliza en casos donde el rango de números es más limitado. Debido a que este rango más limitado solo requiere 8 bits de memoria por valor para el almacenamiento (es decir, 1 byte), solo se necesita la mitad de espacio de memoria o disco duro para cada imagen, comparado con los enteros. Este tipo de datos es probablemente el más comúnmente usado en SIG ya que provee un rango adecuado para describir la mayoría de los grupos de datos de mapas cualitativos y virtualmente todos los datos de sensores remotos.
3. Los números reales tienen una parte fraccional, como 3,14. Éstos se usan siempre que una variable de datos continua (en lugar de discreta) se guarda con gran precisión, o siempre que el rango de datos excede aquél de los datos enteros. El tipo de datos reales de las imágenes raster de IDRISI se conoce como números reales de precisión. Este tipo puede guardar valores dentro de un rango de  $\pm 1 \times 10^{38}$  con una precisión de 7 cifras significativas. Los valores de precisión brindan un buen balance entre rango, precisión y volumen de datos. Cada número (y por lo tanto, cada pixel) requiere 4 bytes para ser almacenados. Observe que los números reales no poseen una representación discreta (Ej.: 4,0 es lo mismo que 3.999999999999999999 en algún nivel de precisión). Entonces, mientras que es posible guardar números completos en un tipo de datos reales, no pueden ser usados como identificadores de características (Ej.: para ASSIGN o EXTRACT) o en módulos que requieren valores byte o enteros (Ej.: GROUP).
4. Los archivos de datos RGB24 usan 24 bits (3bytes) por cada pixel para codificar imágenes en color. La estructura interna es banda intercalada por pixel y puede codificar más de 16 millones de colores separados. Las imágenes RGB24 también se construyen con el módulo COMPOSITE (en el menú de Visualización-Display). El sistema de visualización de IDRISI permite la manipulación interactiva e independiente del contraste de las tres bandas de entrada de una imagen RGB24 visualizada. Éstos son el formato preferido para la visualización de las imágenes.

El archivo de documentación asociado con cada imagen almacena el tipo de archivo de datos. Cuando una nueva imagen es creada, ésta mantiene el tipo de datos dominante de la imagen de entrada, o produce un tipo de datos lógico basado en reglas estándar de aritmética mixta. Entonces, al dividir una imagen con datos enteros por una segunda imagen con datos enteros produce una imagen con datos reales. IDRISI acepta tipos de datos enteros, byte y reales para casi todas las operaciones que por lógica permitirían esto. Algunos módulos, en cambio, no sirven con datos reales. Por ejemplo, la operación GROUP, que extrae grupos contiguos, solo puede realizar esto con datos categóricos codificados con números enteros. Si el tipo de datos en una imagen es incorrecto para una operación en particular, se mostrará un mensaje de error.

El módulo CONVERT puede usarse en cualquier momento para convertir los tipos de datos enteros, byte y reales. En el caso de la conversión de números reales a formatos tanto enteros como byte, CONVERT ofrece la opción de convertirlos por redondeo o truncamiento (recorte).

El tipo de datos descrito anteriormente indica el tipo de números almacenados en una imagen. Otro parámetro, el tipo de archivo, indica cómo son almacenados estos números. En lo que se refiere al tipo de datos, el tipo de archivo de una imagen es guardado en su archivo de documentación. Los archivos de imágenes pueden guardarse en formatos ASCII, binario o binario cerrado, aunque solo se recomienda el formato binario (por razones de eficiencia). Los archivos binarios son aquellos almacenados en el formato original de codificación binaria del sistema operativo en uso. En el caso de IDRISI, ésta será una de las variantes del sistema operativo Windows. Entonces, por ejemplo, el código binario de un número real es aquél adoptado por Windows y por la plataforma hardware de Intel.

Los archivos binarios son eficientes tanto en la utilización del espacio del disco duro como en el tiempo de procesamiento. Sin embargo, el formato no es universal y no siempre es muy accesible. Como consecuencia, IDRISI también provee asistencia limitada para los datos guardados en formato ASCII. Un archivo en formato ASCII es llamado además archivo de *texto*, y puede verse directamente con cualquier editor de textos (como el módulo Edit de IDRISI). El tipo de archivo ASCII es usado principalmente para transferir archivos desde y hacia otros programas, ya que el sistema de codificación es un estándar reconocido (ASCII = American Standard Code for Information Interchange – Código Americano Estándar para el Intercambio de Información). Los archivos ASCII no son un medio eficiente para almacenar datos y no pueden ser visualizados. El módulo CONVERT convierte archivos de formato ASCII en binario o viceversa. Aunque los archivos binarios no pueden ser examinados directamente, IDRISI provee utilidades potentes para el examen de datos a través del Explorador de Archivos (File Explorer) de IDRISI en el menú Archivo (File menu). Los archivos binarios pueden verse como una matriz de números usando la utilidad Estructura de Visualización (View Structure) del Explorador de Archivos. Entonces, rara vez hay necesidad de convertir imágenes a formato ASCII.

El formato binario cerrado es un formato especial de compresión de datos para datos binarios enteros o byte, conocido como codificación de longitud (run-length). Éste tenía un rol especial en versiones anteriores en MS-DOS de IDRISI antes de que la compresión de archivos estuviera disponible a nivel de sistemas operativos. No obstante, ahora este formato es de uso limitado, ya que Windows tiene un rol activo en la compresión de datos. Su ayuda es en gran medida para propósitos de compatibilidad con versiones anteriores de IDRISI. Como los archivos ASCII, la mayoría de los módulos de IDRISI aún aceptan el tipo de datos binario cerrado. Sin embargo, como los archivos ASCII, los archivos binarios cerrados no pueden mostrarse directamente. El uso de este tipo de archivos tampoco se recomienda. Como con otras conversiones, la conversión de imágenes raster hacia o desde el formato binario cerrado es realizada con el módulo CONVERT.<sup>18</sup>

## Archivos Raster de Documentación (.rdc)

Cada uno de los principales tipos de archivos usados por IDRISI (Raster, Vectoriales y de Atributo) está asociado con un archivo acompañante de documentación. A los archivos raster de documentación, IDRISI les asigna automáticamente una extensión de archivo “.rdc”.

Los archivos de documentación siempre se guardan en formato ASCII. Pueden ser visualizados y modificados usando la utilidad Metadata de la barra de herramientas o del menú Archivo. Luego de especificar el tipo de archivo que desea ver, Ud. puede seleccionar un archivo de ese tipo eligiéndolo de la lista de archivos. Los contenidos de su archivo de documentación serán visualizados.

El archivo de documentación consiste en una serie de líneas que contienen información vital acerca del archivo de imagen correspondiente. Los primeros 14 caracteres describen los contenidos de la línea, mientras que el resto de los caracteres contiene los datos reales. Por ejemplo, el archivo de documentación para una imagen de suelos (suelos.rst) puede verse de la siguiente manera:

```
Formato del archivo: IDRISI Raster A.1
Título del archivo: Grupos de Suelos Más Importantes
Tipo de datos: byte
Tipo de archivo: binario
Columnas: 512
Filas: 480
Sistema de referencia: US83TM18
Unidades de referencia: m
Unidad de distancia: 1
X Mín.: 503000
X Máx.: 518360
Y Mín.: 4650000
Y Máx.: 4664400
Error de posición: desconocido
Resolución: 30
Valor Mín.: 0
Valor Máx.: 3
Visualización Mín.: 0
```

---

<sup>18</sup> Hay algunas consideraciones importantes al determinar si el formato cerrado reducirá en realidad los requerimientos para el almacenamiento de datos. *En primer lugar, el formato binario cerrado solo ahorrará espacio donde hayan celdas con una frecuencia de valores idénticos una al lado de la otra.* Vea la descripción del módulo CONVERT en el Sistema de Ayuda on-line para obtener algunos consejos importantes relacionados con el tema.

Visualización Máx.: 3  
Unidades de valores: clases  
Error de valores: 0,15  
Valor de bandera: 0  
Definición de bandera: fondo  
Leyendas: 3  
Código 1: Suelos Podzol  
Código 2: Suelos Podzol Marrones  
Código 3: Suelos Podzol MarrónGrisáceos  
Linaje: Polígonos del suelo derivados de una fotografía aérea color en escala 1:5000  
Linaje: y la verdad de campo, con la compilación final ajustada a  
Linaje: a mano a la base del mapa.  
Comentario: Error de los valores determinado por una evaluación de exactitud estadística  
Comentario: basada en una muestra aleatoria estratificada de 37 puntos.

Este archivo contiene información sobre los principales grupos de suelos y está en formato byte, almacenado como un archivo binario. Esta imagen contiene 512 columnas y 480 filas, para un total de 245.760 valores. La imagen esta georeferenciada por un sistema de referencia llamado US83TM18<sup>19</sup> donde cada unidad de coordenadas representa 1 metro. El mínimo y máximo de los valores de las coordenadas X e Y indican las coordenadas del sistema de referencia de los bordes izquierdo, derecho, superior e inferior.

El error de posición indica cuán cerca está la posición real de una característica de su posición cartográfica en la imagen. En el ejemplo esto figura como desconocido. Si se conoce, este campo debe grabar el error RMS (Root Mean Square) (Error Medio Cuadrático) de referencias de localización derivadas de las coordenadas del rectángulo delimitante. Este campo es solamente para fines de documentación y no es usado actualmente por ningún módulo.

La resolución se refiere a la resolución inherente de la imagen. En la mayoría de los casos, debe corresponder con el resultado de la división entre el rango de coordenadas de referencia en X (o Y) por el número de columnas (o filas) en la imagen. No obstante, existen algunas instancias poco comunes donde la resolución puede diferir de este resultado. Un buen ejemplo es el caso de las imágenes en Banda 6 de LANDSAT (campo termal). La resolución de estos datos es de 120 metros, en realidad, y es grabada como tal en este campo. Sin embargo, los datos son distribuidos en un aparente formato de 30 metros para hacer coincidir físicamente las dimensiones de las demás bandas en la imagen. Esto se logra duplicando cada pixel de 120 metros 4 veces en el eje X, y luego cada fila 4 veces en el eje Y. El campo de la resolución es una manera de indicar correctamente la resolución subyacente de estos datos.

En la mayoría de las imágenes, la resolución en X e Y será igual (es decir, los pixeles serán cuadrados). No obstante, cuando este no es el caso, se guarda la resolución más gruesa en el archivo de documentación.<sup>20</sup> Por ejemplo, con los datos MSS de LANDSAT, la resolución del pixel es de 80 metros en el eje X y de 60 metros en el eje Y. En este caso, el archivo de documentación mostrará un valor de resolución de 80. Los pixeles rectangulares se mostrarán correctamente, en cambio, preservando la verdadera resolución en ambos ejes X e Y. Además, todos los módulos analíticos que usan medidas de distancia o de área calculan la resolución en X e Y en forma independiente. Éstos no dependen entonces del valor de resolución guardado en el archivo de documentación.

Los campos de los valores mínimos y máximos graban el rango verdadero de los valores de datos que se da a las celdas de las imágenes, mientras que los valores de visualización *mín.* y *máx.* designan lo que a veces se llama *puntos de saturación* del rango de datos. A los valores menores o iguales a la visualización *mín.* se les asigna el color más bajo en la secuencia de la paleta, mientras que a los valores mayores o iguales a la visualización *máx.* se les asigna el color más alto en la secuencia de la paleta. A todos los valores ubicados en el medio se les asigna colores de la paleta de acuerdo a su posición en el rango (es decir, con una extensión lineal). Es muy común que la visualización *mín.* y *máx.* coincida con los valores *mín.* y *máx.* No obstante, en los casos en que uno desea ajustar el brillo y contraste de la imagen, al alterar también los puntos de saturación se puede producir un mejoramiento significativo.<sup>21</sup> Los puntos de saturación pueden manipularse interactivamente en el sistema de visualización (ver el capítulo **Sistema de Visualización**, en este volumen).

<sup>19</sup> El sistema de referencia indicado en el archivo de documentación es el nombre de un archivo de parámetros del sistema de referencia (.ref). Los parámetros de este archivo se detallan en el capítulo **Georeferenciamiento**, de este volumen.

<sup>20</sup> Las versiones anteriores de IDRISI calculaban e informaban el campo de resolución como el de la dimensión X solamente.

<sup>21</sup> Observe que normalmente uno solo cambiaría los puntos de saturación con datos cuantitativos. En el ejemplo ilustrado aquí, los valores numéricos representan clases cualitativas. En estos casos, los puntos de saturación deben coincidir con los valores mínimos y máximos reales.

En este ejemplo, estas unidades de valores muestran *clases* para indicar que los números son simplemente códigos cualitativos para las clases de suelos y no valores cuantitativos. El campo de unidades de valores es solamente informativo, por lo tanto, puede usarse cualquier descripción. Se sugiere usar el término *clases* para todos los juegos de datos cualitativos. Por otra parte, cuando las unidades lineales estándar son apropiadas, deben usarse las mismas abreviaturas que las usadas para unidades de referencia (m, ft, mi, km, deg, rad).

El campo de error de valores es muy importante y debe llenarse siempre que sea posible. Éste graba el error en los valores de los datos que aparecen en las celdas de las imágenes. Para los datos cualitativos, este debe guardarse como un error proporcional. En el ejemplo, el error es guardado como 0,05, indicando una precisión de celda del 85 % (es decir, lo que está representado en el mapa se espera encontrar sobre el suelo un 85% de las veces). Para los datos cuantitativos, el valor debe ser una cifra de error RMS. Por ejemplo, para una imagen de elevación, un error RMS de 3 indicaría el 68% de todos los valores que estén dentro de los  $\pm 3$  metros del valor en el mapa, que aproximadamente el 95% estará dentro de los  $\pm 6$  metros, etc. Este campo es analítico para algunos módulos (Ej.: PCLASS) y se piensa en incorporarlo a más módulos en el futuro.

Los campos de valor y de definición de bandera pueden usarse para indicar cualquier significado especial que puedan tener ciertos valores de las celdas. El valor de bandera muestra el valor numérico que indica una bandera, mientras que la definición de bandera describe la naturaleza de las áreas con banderas. Las banderas de datos más comunes son aquellas usadas para señalar las celdas de fondo y las celdas con datos perdidos. Estas entradas del campo de definición de bandera son específicamente reconocidas y utilizadas analíticamente por algunos módulos (Ej.: SURFACE-Superficie). Otros términos serán considerados solo informativos en esta etapa. Observe que algunos módulos, además, producen banderas de datos. Por ejemplo, cuando se usa el SURFACE para crear una imagen de aspecto, a aquellos aspectos derivados de una pendiente cero se les coloca una bandera con un -1 (para indicar que el aspecto no puede ser evaluado). En el archivo de salida de documentación, el campo de valor de bandera dice -1, mientras que el campo de definición de bandera dice “aspecto no evaluado, pendiente=0”.

El campo de la leyenda graba el número de leyendas almacenadas en el archivo. A continuación, cada leyenda es descrita, incluyendo el código de símbolo (un valor de 0-255) y la leyenda del texto.

Finalmente, la estructura del archivo de documentación de la imagen permite cualquier número de anotaciones en cuatro campos opcionales: comentario (comment), linaje (lineage), consistencia (consistency) y terminación (completeness). En la actualidad, estos campos solo son para información y no son leídos por los módulos de IDRISI (aunque algunos módulos los escriben). Observe que los campos de linaje, consistencia y terminación están diseñados para cumplir con las recomendaciones del U.S. National Committee for Digital Cartographic Data Standards (NCDCCDS) (Comité Nacional de los EE.UU. para el Reglamento de Datos Cartográficos Digitales). Junto con los campos de error de posición (pos'n) y de error de valores, estos campos proveen un medio para adecuarse al estándar actual para informar sobre la calidad de los datos cartográficos digitales.<sup>22</sup> Pueden necesitarse anotaciones múltiples en cualquiera de estos tipos de campo (*pero sólo al final del archivo*) siempre y cuando estén correctamente indicados en el campo descriptivo de 14 caracteres ubicado a la izquierda. El campo linaje puede usarse para grabar la historia de una imagen. La sintaxis usada para generar un nuevo archivo es guardada en el campo linaje del archivo de documentación. El usuario puede agregar cualquier número de líneas adicionales. El campo consistencia se usa para informar sobre la consistencia lógica del archivo; tiene una aplicación particular para los archivos vectoriales, donde son informadas las cuestiones de errores topológicos. El campo de terminación se refiere al grado en el cual el archivo describe de manera comprensiva el tema indicado. Puede grabar, por ejemplo, la unidad cartográfica mínima por la cual las características más pequeñas fueron eliminadas. Por último, el campo de comentario puede usarse para cualquier finalidad informativa que se desee. Advierta que la utilidad Metadata y el módulo CONVERT leen y mantienen estos campos opcionales. Metadata, además, permite ingresar, borrar o actualizar campos de esta naturaleza (así como también cualquier campo de archivos de documentación).

## Capas Vectoriales (.vct)

IDRISI admite cuatro tipos de archivos vectoriales: de punto, línea, polígono y de texto.<sup>23</sup> Todos son automáticamente almacenados con extensión de archivo “.vct”. Son guardados en una estructura de características codificadas en la que cada característica es descrita por completo antes de que sea descrita la próxima. La sección

<sup>22</sup> Para obtener más información sobre el estándar NCDCCDS, diríjase a la publicación de enero de 1988 llamada *The American Cartographer*, Volumen 15, Nro. 1.

<sup>23</sup> Observe que las estructuras del archivo vectorial binario para Idrisi32 son diferentes a las de versiones anteriores. Consulte el Sistema de Ayuda on-line para más detalles.

File Structures (Estructuras de Archivos) del Sistema de Ayuda on-line brinda detalles específicos sobre las estructuras de cada tipo de archivo vectorial. Además, los archivos vectoriales pueden verse como representaciones ASCII usando la función Ver Estructura (View Structure) del Explorador de Archivos de IDRISI. Sin embargo, las siguientes descripciones brindan toda la información que la mayoría de los usuarios necesita.

## Características Comunes de Todos los Archivos Vectoriales

Todos los archivos vectoriales describen una o más características distintas. A diferencia de las imágenes raster, que describen la totalidad del espacio dentro de una región rectangular, los archivos vectoriales pueden describir solo un pequeño número de características dentro de una región rectangular definida de manera similar.

Cada característica es descrita por medio de un solo valor de atributo numérico y por uno o más pares de coordenadas X,Y que describen la ubicación, curso y bordes de esa característica. Cuando son dibujados, estos puntos son unidos por segmentos de líneas rectas. Entonces, por sus características, los arcos requieren un gran número de puntos con poco espacio de separación para dar la apariencia de curvas suaves.

Los valores de atributos numéricos pueden representar tanto identificadores (para unirse a los valores en una tabla de datos) como valores de datos numéricos reales, y pueden almacenarse como números enteros o reales (aunque los identificadores deben ser enteros).<sup>24</sup>

Una característica especial de los archivos vectoriales es que sus tipos de datos (enteros o reales) son menos específicos en su significado que los archivos raster. El tipo de datos enteros tiene un rango muy amplio, y es compatible con ambos tipos de capas raster: byte y enteras, así como también el tipo de datos enteros largos comúnmente usado para los identificadores en las tablas de bases de datos. Aproximadamente, el tipo de datos enteros vectoriales cubre el rango de números enteros desde  $-2.000.000.000$  a  $+2.000.000.000$ . De la misma manera, el tipo de datos reales vectoriales es compatible con los números reales de precisión única de las capas raster, pero, en verdad, estos datos son almacenados como números reales de precisión doble, con un mínimo de 15 cifras significativas. Los procedimientos de IDRISI de conversión de vectoriales a raster manejan estas traducciones automáticamente, por lo que hay pocos motivos para preocuparse por estos detalles. Simplemente tenga en cuenta que los valores enteros representan números enteros y los números reales incluyen partes fraccionales.

## Archivos Vectoriales de Puntos

Los archivos de puntos se usan para representar características para las que sólo tiene importancia la ubicación (como un solo punto de ubicación designada). Algunos ejemplos incluyen datos de estaciones meteorológicas, bocas de agua contra el fuego, ciudades y pueblos (cuando su extensión de área no es de interés). Cada característica de punto se describe con un valor de atributo que puede ser entero o real, y con un par de coordenadas X,Y.

## Archivos Vectoriales de Línea

Los archivos lineales describen características lineales tales como ríos y caminos. Cada característica lineal en una capa se describe por medio de un valor de atributo que puede ser entero o real, un recuento del número de puntos que forman la línea y por una serie de pares de coordenadas X,Y (una para cada punto).

## Archivos Vectoriales de Polígono

Los archivos vectoriales de polígonos describen características aéreas como regiones boscosas o áreas estudiadas por un censo. Cada característica poligonal en una capa poligonal es descrita por un valor de atributo que puede ser entero o real, por un recuento del número de *partes* en el polígono y, para cada parte, una lista de los puntos (por medio de un índice interno) que forman esa parte. A esto le sigue una lista indexada de los pares de coordenadas X,Y de todos los puntos en el polígono. Las partes de un polígono están relacionadas con el tema de las islas dentro de él. Un polígono con una parte no tiene islas o cavidades, mientras que uno con dos partes posee una isla o cavidad. La primera parte de la lista es siempre el polígono que encierra las islas.<sup>25</sup>

---

<sup>24</sup> Todas las características en una sola capa vectorial deben ser codificadas con valores numéricos del mismo tipo. Entonces, si se usan identificadores enteros, todas las características deben tener identificadores enteros. De manera similar, si se codifican atributos de números reales, todas las características en esa capa deben tener atributos de números reales.

<sup>25</sup> Advierta que las islas son tratadas por IDRISI como polígonos separados. Por lo tanto, si uno toma el caso del Estado de Hawái como ejemplo, uno puede considerarlo como un solo polígono con cinco partes. En IDRISI, en cambio, esto equivaldría a cinco polígonos diferentes. Sin embargo, éstos pueden tener el mismo identificador, lo que les permite estar unidos a una misma entrada de datos en una tabla de base de datos.



## Archivos Vectoriales de Texto

Los archivos vectoriales de texto representan textos de leyendas que puede mostrarse como una capa sobre un mapa. Éstos almacenan el texto de la leyenda, su posición y orientación, y un código de símbolos que puede usarse para unirlos a un archivo de texto de símbolos. Los archivos vectoriales de texto pueden crearse con una función de digitalización sobre pantalla de IDRISI o exportando textos desde una cobertura de CartaLinx. Los archivos de texto de símbolos son creados con el Taller sobre Símbolos (Symbol Workshop).

## Archivos Vectoriales de Documentación (.vdc)

Al igual que con los archivos de imágenes, todos los archivos vectoriales se encuentran de a pares, junto con sus archivos de documentación. Los archivos vectoriales de documentación tienen una extensión “.vdc”. Cualquier módulo de IDRISI que crea o importa un archivo vectorial creará automáticamente un archivo de documentación. La utilidad Metadata puede usarse para actualizar o crear archivos de documentación según se desee.

Un ejemplo de archivo vectorial de documentación luce de la siguiente manera:

Formato del archivo: IDRISI Vectorial A.1  
Título del archivo: Uso del suelo / Cubierta terrestre  
Tipo de id: entero  
Tipo de archivo: binario  
Tipo de objeto: polígono  
Sistema de referencia: utm16spe  
Unidades de referencia: m  
Unidades de distancia: 1  
X mín: 296000  
X máx: 316000  
Y mín: 764000  
Y máx: 775000  
Error de posición: desconocido  
Resolución: desconocida  
Valor mín.: 1  
Valor máx.: 9  
Visualización mín.: 1  
Visualización máx.: 7  
Unidades de valores: clases  
Error de valores: 0,15  
Valor de bandera: 9  
Definición de bandera: desconocida: oscurecida por nubes  
Leyendas: 7  
Código 1: Residencial  
Código 2: Industrial  
Código 3: Comercial  
Código 4: otros terrenos urbanos o construidos  
Código 5: aguas abiertas  
Código 6: estéril  
Código 7: de transición

Como se puede ver, la estructura de un archivo vectorial de documentación es virtualmente idéntico al de una capa raster. Las únicas diferencias son:

1. la información de la fila y columna está ausente;
2. el *tipo de datos* ha sido reemplazado por el *tipo de id*, aunque la intención es la misma. Las opciones aquí son enteros o reales. La razón por la cual existe una mínima diferencia en el vocabulario es debido a que las coordenadas son siempre almacenadas como números reales de precisión doble. Los identificadores (id), en cambio, pueden variar en el tipo de datos según si éstos codifican identificadores o valores de atributos numéricos.
3. el tipo de archivo es siempre binario.(el formato ASCII para los archivos vectoriales es asistido a través del Vector Export Format – formato de exportación de vectores)

- los valores mínimos y máximos de X e Y almacenados en el archivo de documentación no se refieren necesariamente a las coordenadas mínimas y máximas asociadas con alguna característica sino a los bordes o límites del área de estudio. Entonces, estos valores corresponden a las coordenadas BND (bordes) de los sistemas vectoriales como Arc/Info.

## Archivos de Atributos (.mdb y .avl)

Además de los atributos almacenados directamente en las capas raster o vectoriales, IDRISI permite el uso de archivos de atributos independientes. Hay dos tipos: tablas de datos y archivos de valores. Sólo el primero de estos tipos puede ser unido a un archivo vectorial para su visualización o para producir una colección vectorial. El segundo puede usarse para asignar nuevos valores a una imagen raster y es producido cuando se extraen valores de resumen desde una imagen raster. Los campos de una tabla de datos pueden ser exportados como archivos de valores y a su vez éstos pueden ser importados en las tablas de datos usando el Taller sobre Bases de Datos.

### Tablas de Datos (.mdb)

Las tablas de datos de IDRISI son archivos de bases de datos relacionales compatibles con Microsoft Access. Entonces, las tablas de atributos de IDRISI poseen una extensión “.mdb”. Internamente, cada una puede llevar múltiples tablas, y también pueden ser usadas y modificadas con Microsoft Access u otro sistema compatible con Access.

### Archivos de Valores (.avl)

Los archivos de valores contienen los valores para un solo atributo. Son almacenados en formato de texto ASCII con dos columnas de datos separadas por uno o más espacios. La primera columna contiene un identificador que puede ser usado para asociar el valor con una característica (tanto raster como vectorial), mientras que la segunda columna contiene el valor del atributo. Los archivos de valores de atributos tienen una extensión “.avl”. La siguiente es una ilustración de un archivo de valores simple que enumera las poblaciones (\*1000) de las 10 provincias de Canadá: donde 1 = Newfoundland, 2 = Nova Scotia, 3 = Prince Edward Island, etc.

- 560
- 850
- 129
- 690
- 6360
- 8889
- 1002
- 956
- 2288
- 2780

La imagen de definición de características a ser usada con este archivo de valores va a tener el valor 1 para todos los píxeles en Newfoundland, el valor 2 para Nova Scotia, etc.

### Archivos de Documentación de Atributos (.adc)

De la misma manera que con los archivos de imágenes y vectoriales, los archivos de atributos (de cualquier tipo) también llevan archivos de documentación, pero esta vez con una extensión “.adc”. De forma similar, Metadata es la utilidad que se utiliza para crear o modificar el archivo de documentación asociado con un archivo de atributos.

Al igual que con los demás archivos de documentación en IDRISI los archivos de atributos son almacenados en formato ASCII con los primeros 14 caracteres usados exclusivamente para fines descriptivos.

Un ejemplo de un archivo de documentación de atributos se ve de la siguiente manera:

Formato del archivo: IDRISI Valores A.1  
Título del archivo: Caminos  
Tipo de archivo: ascii  
Registros: 12  
Campos: 2  
Campo 0: IDR\_ID

Tipo de datos: enteros  
 Formato: 0  
 Valor mín.: 105  
 Valor máx.: 982  
 Visualización mín.: 105  
 Visualización máx.: 982  
 Unidades de valores: ids  
 Error de valores: desconocido  
 Valor de bandera: ninguno  
 Definición de bandera: ninguno  
 Leyendas: 0  
 Campo 1: TIPO\_CAMINO  
 Tipo de datos: enteros  
 Formato: 0  
 Valor mín.: 1  
 Valor máx.: 3  
 Visualización mín.: 1  
 Visualización máx.: 3  
 Unidades de valores: clases  
 Error de valores: desconocido  
 Valor de bandera: ninguno  
 Definición de bandera: ninguna  
 Leyendas: 3  
 Código 1: Camino principal  
 Código 2: Camino secundario  
 Código 3: Camino menor

Este ejemplo muestra el archivo de documentación para un archivo de valores de atributos ASCII. Este tipo de archivo siempre tiene dos campos. Las tablas de bases de datos, por lo general, tienen muchos más campos. Para cada campo, los parámetros mostrados se repiten.

En esta versión de IDRISI, los siguientes tipos de archivos son aceptados:

#### *ascii*

Archivos de formato ASCII de 2 columnas, donde el campo izquierdo contiene identificadores de características enteras y el campo derecho contiene datos sobre esas características. Estos archivos de valores tienen una extensión de archivo “.avl”.

#### *access*

Archivo de base de datos en formato Microsoft Access con extensión “.mbd”. Éste es el formato actual de bases de datos residentes aceptado por IDRISI, y es asistido por el Taller sobre Bases de Datos. También es el formato usado en la creación y visualización de colecciones vectoriales.

En el caso de la forma ASCII simple (archivo “.avl”), la información del formato no es importante, y por lo tanto tiene una lectura de 0 en este ejemplo. Los espacios o tabs pueden usarse para separar los campos. Con archivos ASCII de longitud fija y archivos de bases de datos, la información del formato es esencial. La línea del formato simplemente indica el número de posiciones de caracteres ocupados por el campo.

#### *datos byte y enteros*

Un número solo para indicar el número de posiciones de caracteres a ser usados.

#### *datos de caracteres secuenciales*

Un número solo para indicar el número máximo de caracteres.

#### *datos de números reales*

Dos números separados por dos puntos para indicar el número total de columnas y el número de aquellas columnas que van a ser usadas para guardar valores decimales. Por ejemplo, 5:2 indica que se van a utilizar cinco columnas, dos de las cuales son para los lugares decimales. Observe que el mismo signo decimal ocupa una de estas columnas. Entonces, el número “25.34” ocupa por completo este campo.

Para la mayoría de las otras entradas, la interpretación es la misma que se aplica a las capas de imágenes raster. Los tipos de datos válidos incluyen: *byte*, *enteros*, *reales* y *secuenciales* (para datos de caracteres). Sin embargo, para las tablas de datos (.mdb), muchos de los tipos de datos reconocidos por Microsoft Access Jet Engine están aceptados. Estos incluyen:

- reales (-3,402823E38 a +3,402823E38, números reales)
- byte (0-255, números enteros)
- enteros (-32768 a 32767, números enteros)
- enteros largos (-2.147.483.648 a 2.147.483.647, números enteros)
- texto (secuencias de caracteres)
- booleano (verdadero o falso)

IDRISI documenta estos tipos en forma automática, y sabe cómo convertirlos cuando se usan en el contexto de visualización (en una colección vectorial) o cuando se crea un archivo de valores ASCII.

## Otros Tipos de Archivos

Mientras que la mayoría de los archivos de datos con los que Ud. trabajará son aquellos que describen capas y sus atributos, existen muchos otros dentro del sistema IDRISI y algunos de ellos se describen a continuación. Otros tipos de archivos más especializados se describen en el contexto de módulos específicos y en la sección Estructuras de Archivos del Sistema de Ayuda on-line.

## Archivos de Composición de Mapas (.map)

Los archivos de composición de mapas almacenan las instrucciones gráficas necesarias para crear una composición cartográfica usando datos de un juego de capas de mapas y de campos asociados de símbolos y de paleta. Éstos se describen con más detalle en el capítulo **Sistema de Visualización** de este volumen.

## Archivos de Símbolos y de Paleta (.sm0, .sm1, .sm2, .smt, .smp)

Para poder visualizar las capas de los mapas, es necesario establecer una asociación entre las características vectoriales o valores de las imágenes e interpretaciones gráficas particulares. Esto se realiza a través de los **Archivos de Símbolos** y **Archivos de Paleta**. Un grupo de archivos de símbolos y de paleta está incluido en IDRISI, y puede cubrir la mayoría de las necesidades del usuario. Sin embargo, para la producción final, a menudo se prefiere crear archivos de símbolos y de paleta personalizados. Esto se lleva a cabo con la utilidad Taller sobre Símbolos (Symbol Workshop) en el menú Visualización (Display Menu). Ver el capítulo **Sistema de Visualización** de este volumen para obtener más información acerca del Taller sobre Símbolos.

Los archivos de símbolos indican la forma en la que las características vectoriales deben ser simbolizadas (como el tipo, grosor y color de las líneas, o la fuente, estilo, tamaño y color del texto). Cada archivo de símbolos considera las características de hasta 256 símbolos que son identificados por números indexados de 0 a 255. En total, se usan cuatro tipos de archivos de símbolos, uno para cada tipo de característica vectorial: punto, línea, polígono y texto. Éstos son almacenados con extensiones de archivo “.sm0,” “.sm1,” “.sm2” y “.smt”, respectivamente. Como sucede usualmente, IDRISI siempre reconoce el tipo de símbolo apropiado a usar. Como resultado, nunca se requiere especificar un archivo de símbolos con su extensión.

Para las imágenes raster, las interpretaciones gráficas se especifican a través del uso de archivos de paleta. Como los archivos de símbolos, los archivos de paleta también definen hasta 256 interpretaciones identificadas por números indexados de 0 a 255. No obstante, en este caso, sólo la mezcla de colores (definida por las relativas cantidades de los colores primarios rojo, verde y azul) se especifica. Los archivos de paleta son almacenados con una extensión “.smp”.<sup>26</sup>

## Archivos de Parámetros de Sistemas de Referencia (.ref)

Los archivos de parámetros de sistemas de referencia graban información acerca de sistemas específicos de referenciamiento geográfico. Incluyen datos sobre las convenciones en uso de proyección, elipsoide, información y numeración de un sistema de referenciamiento. IDRISI incluye más de 400 archivos de este tipo. El usuario puede modificarlos y además crear nuevos archivos de parámetros de sistemas de referencia con la función Metadata. Ver el capítulo Georeferenciamiento de este volumen, para más información sobre estos archivos.

---

<sup>26</sup> La versión MS-DOS de IDRISI usaba una estructura diferente para los archivos de paleta con una extensión “pal”. El módulo PALIDRIS, en el grupo de importación puede leer y convertir estos archivos.


# CAPÍTULO 6 - Sistema de Visualización

## Introducción

El capítulo anterior describió las capas de los mapas en su representación de un solo tema elemental. Al combinar las capas de mapas y al darle interpretaciones gráficas, creamos un mapa. Las composiciones de mapas (map compositions) pueden contener un mínimo de una capa y un máximo de 32 capas. Las composiciones de mapas son creadas como consecuencia natural del trabajo con el sistema de visualización de IDRISI. Mientras Ud. trabaja, IDRISI va guardando todos los cambios y agregados que se le efectúan a la composición. Luego se puede guardar en cualquier momento. La composición es almacenada en un archivo con extensión “.map” y se lo llama simplemente un archivo de mapa. El sistema de visualización de IDRISI consiste en varios componentes de programa separados pero interdependientes, cada uno de los cuales se describe en este capítulo.

## Lanzador de la VISUALIZACIÓN

El lanzador de la VISUALIZACIÓN (DISPLAY Launcher) se usa para abrir una nueva ventana de visualización. Comienza el proceso de composición de mapas, y es siempre la primera operación requerida para crear una nueva visualización cartográfica. El lanzador de la VISUALIZACIÓN puede accederse desde su icono de la barra de herramientas (que se muestra abajo) o eligiéndolo desde el menú Visualización. Al hacer esto, se abre un cuadro de diálogo con opciones para visualizar una capa raster, vectorial o una composición de un mapa ya existente.



Cuando Ud. selecciona una capa raster o vectorial, IDRISI usa un juego de reglas de decisión basadas en los valores de la capa para sugerir un archivo de símbolos o de paleta apropiado. Esta selección se puede cambiar. Ud. también debe especificar si la capa debe ser visualizada con una relación directa entre los valores numéricos y los códigos de símbolos, o si debe tener una escala automática (ver abajo). En el caso de una composición de mapa, sólo se le pedirá que especifique su nombre, ya que todos los parámetros de visualización están almacenados en el archivo del mapa. Vea el capítulo **Panorama General del Sistema** en este volumen para obtener opciones sobre la elección de los nombres de los archivos. Ésta puede realizarse de la lista de selección o tipeando los nombres directamente. Haga clic en OK para mostrar la capa del mapa o su composición.

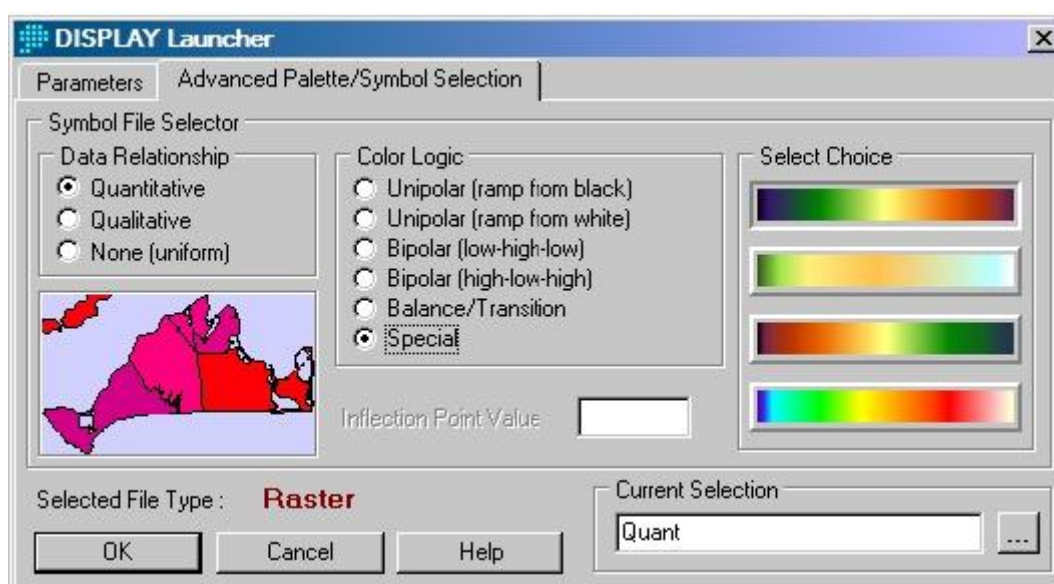
## Archivos de Símbolos y de Paleta

Los archivos de paleta definen la manera en que la información almacenada en los valores de los pixeles de las imágenes será visualizada en la pantalla. De la misma forma, los archivos de símbolos definen la manera en que van a aparecer las características vectoriales con los identificadores *id* particulares o con valores de atributos asociados.

Cada uno almacena el carácter de hasta 256 interpretaciones gráficas referenciadas por números indexados de 0-255. Los archivos de paleta guardan la mezcla de colores Rojo, Verde y Azul (RGB) para cada índice, mientras que los archivos de símbolos guardan una variedad de parámetros relacionados con tipos específicos de objetos vectoriales (Ej.: punto, tamaño, ancho de línea, color, etc). La sección que sigue sobre el Taller de Símbolos presenta los parámetros que pueden ser definidos para cada tipo de archivo de símbolos. IDRISI viene con un juego de archivos estándar de paleta y de símbolos. Éstos están instalados en la carpeta de símbolos del directorio de programa de Idrisi Selva (Ej.: C:\Idrisi Selva\Symbols). Ud. puede extender este juego, modificando archivos de paleta y de símbolos existentes, o creando archivos completamente nuevos. El Taller de Símbolos puede usarse para este propósito. Los archivos de paleta y de símbolos creados por el usuario pueden guardarse en cualquier parte, incluyendo el directorio de símbolos de Idrisi. Generalmente, los usuarios guardan los archivos de símbolos comúnmente usados en el directorio de Símbolos. Los archivos que son específicos de grupos de datos particulares son por lo general guardados con esos datos.

## Selección Avanzada de Paleta / Símbolo

El lanzador de la Visualización además ofrece una función de Selección Avanzada de Paleta / Símbolo que provee un acceso fácil a más de 1300 archivos de paleta y símbolos.



Primero debe indicar si sus datos expresan variaciones cuantitativas o cualitativas. Los datos cuantitativos expresan diferencias de grado (como la elevación), mientras que los datos cualitativos expresan diferencias de tipo (como las categorías de cubierta terrestre). Alternativamente, Ud. puede indicar que desea simbolizar todas las características con un símbolo uniforme. También tendrá que decidir la lógica de colores. Para cada lógica de colores, Ud. tiene cuatro opciones que pueden ser seleccionadas presionando el botón apropiado. Para los diseños con símbolos Cualitativos y Uniformes, las opciones de la lógica de colores se harán directamente. En cambio, las opciones para los datos cuantitativos necesitan una explicación adicional:

- Las presentaciones unipolares se utilizan para simbolizar datos que progresan en forma ascendente o descendente.
- Las presentaciones bipolares tienen dos puntas altas o bajas, con una inflexión distinta en algún lugar intermedio. Por ejemplo, los datos del cambio en la población pueden oscilar de un +20% a un -20%. En este caso tenemos dos puntas altas – cambio alto positivo y cambio alto negativo, con un punto claro de inflexión al 0%. Los colores en las presentaciones bipolares están diseñados para ser percibidos por el sistema visual como si perteneciesen a dos grupos cualitativos diferentes mientras que mantienen una relación cuantitativa en la secuencia.
- Las presentaciones de balance son menos comunes. Éstas son usadas en los casos donde dos variables co-varían perfectamente, es decir, las disminuciones en una son perfectamente balanceadas por los aumentos en la otra. Por ejemplo, imagínese un país en el cual se usan dos idiomas. Los distritos con un 40% de uno de los idiomas van a tener entonces un 60% del otro. Los colores en las presentaciones de balance están diseñados para ser vistos como mezclas variantes de dos componentes diferentes.

## Escala Automática

La escala automática (*autoscaling*) se ocupa de la relación entre los valores de las celdas raster y los índices de la paleta (y, de forma similar, entre identificadores *id* vectoriales o valores de atributos asociados e índices de símbolos). Por defecto, se asume una relación directa entre éstos (es decir, una celda con un valor numérico de 12 debería visualizarse con el color definido por el índice de paleta 12). No obstante, no todas las imágenes contienen valores enteros que se ubican con comodidad dentro del rango permisible de valores para los índices de paleta. (0-255). Como resultado, a menudo es necesario establecer la escala del rango real de valores en este rango más limitado. Por ejemplo, podemos tener una capa de imagen con anomalías de la temperatura que oscilan entre los (-7,2) grados y los (+4,6) grados. Estos valores no pueden ser visualizados directamente porque no hay un índice de paleta de (-7,2). La escala automática ofrece una solución a este problema:

Se brindan cuatro opciones de escala automática: Directa (Off), Intervalos Iguales (Equal Intervals), Cuantiles y Valores Estándar (Standard Scores).

- Directa (Off). Cuando la escala automática está en off (desconectada), se asume que existe una relación directa entre los valores numéricos de los píxeles o de las características en la capa y los códigos numéricos de los archivos de paletas y símbolos. Entonces, si un pixel contiene el número 5 en una capa, se simboliza con el color 5 de la paleta. Esta opción sólo se permite en los casos en que todos los píxeles o características tiene valores enteros entre 0-255.
- Intervalos Iguales (Equal Intervals). Ésta es la acción por defecto para todos los casos donde la escala directa no es posible – es decir, para los casos en que algunos de los valores de los datos son menores de cero o mayores de 255, y todos los casos donde la capa contiene números reales. En este caso, el rango de los valores numéricos es trazado a escala automáticamente (de ahí el nombre *autoscaling*) en una serie de clases de datos del mismo ancho que son a continuación asignados a símbolos. Entonces, por ejemplo, una capa que contiene elevaciones de 0 a 5000 metros puede ser mostrada a escala de forma automática en 10 clases de 500 metros de ancho. Por lo tanto, los valores de 0-499 serían asignados al símbolo 0, los de 500-999 al símbolo 1, los de 1000-1499 al símbolo 2, etc. El lanzador de VISUALIZACIÓN hará una determinación inicial del número de clases. Sin embargo, existe la posibilidad de especificar cualquier número de 2-256. Recuerde que en IDRISI todas las series numéricas comienzan de 0. Si elige 256 clases, éstas serán interpretadas con códigos de símbolos del 0 al 255. Advierta que este proceso de dividir el rango de los datos numéricos en una serie de clases de simbolizaciones también se le llama clasificación en cartografía.
- Cuantiles. Una presentación de clasificación en cuantiles coloca el mismo número de píxeles o características en cada clase, primero ordenándolos por rango y luego asignándolos a las clases ya ordenadas por rango. Algunas presentaciones en cuantiles se conocen por nombres especiales. Entonces, por ejemplo, a una presentación en cuantiles con cuatro clases se la conoce como una presentación en cuantiles. Una presentación en cuantiles es una buena opción siempre que los datos estén fuertemente distorsionados o desproporcionalmente cargados en un número pequeño de clases de intervalos iguales.
- Valores Estándar (Standard Scores). Una presentación de clasificación estandarizada divide los datos en clases de símbolos basadas en unidades de desviación estándar. Con un número par de clases, el promedio representa el borde central entre las clases, mientras que con un número impar de clases, el promedio estará en el centro de la clase media. Todas las clases son una desviación estándar del ancho y las clases de las puntas siempre incluyen todos los casos por debajo de sus bordes de definición. Por ejemplo, el caso por defecto de 6 clases será definido como:

$\leq -2sd$

$-2sd$  a  $-1sd$

$-1sd$  a la media

media a  $+1sd$

$+1sd$  a  $+2sd$

$\geq +2sd$

mientras que una selección de 5 clases producirá:

$\leq -1.5sd$

$-1.5sd$  a  $-0.5sd$

$-0.5sd$  a  $+0.5sd$

$+0.5sd$  a  $+1.5sd$

$\geq +1.5sd$



Las clases estandarizadas son apropiadas siempre que los datos están prácticamente distribuidos en forma normal y uno desea diferenciar los casos inusuales de aquellos más comunes. Hay muchos más temas que deben destacarse de la escala automática o autoescala. Primero, la autoescala de Intervalos Iguales se activa automáticamente siempre que deben visualizarse los números reales o los valores enteros fuera del rango 0-255. Segundo, mientras que el rango máximo de índices de paleta y símbolos es de 0-255, algunos archivos de paleta o de símbolos pueden usar un rango más limitado de valores con el propósito de trazar una autoescala (Ej.: 1-100). El rango de autoescala de un archivo de paleta o de símbolos puede ser inspeccionado y cambiado con el Taller para Símbolos. Tercero, mientras que la autoescala de Intervalos Iguales trabaja bien para muchas imágenes, aquellas con las distribuciones de los valores de datos totalmente distorsionados (es decir, con un número muy pequeño de valores extremadamente altos y extremadamente bajos) pueden llegar a dar un contraste muy pobre. En muchos casos, Ud. puede alterar los valores de visualización mín. y máx. (Conocidos como los puntos de saturación) usando la opción Propiedades de las Capas del Diseñador (ver abajo). Alternativamente, se puede usar la autoescala Cuantiles. Finalmente, advierta que la autoescala no cambia los valores almacenados en un archivo de datos; sólo altera la visualización. Para crear una nueva imagen raster con valores de contraste de expansión, use el módulo STRETCH.

## Visualización Automática

IDRISI incluye una función de visualización automática que puede ser activada o desactivada desde las Preferencias de Usuario, en el menú Archivo. Con la visualización automática, los resultados de las operaciones analíticas se muestran inmediatamente después de que la operación ha concluido. El sistema determinará si hay que usar la paleta por Defecto Cualitativa o Cuantitativa (las cuales son definidas por el usuario en el diálogo de las Preferencias) para la visualización y si se debe o no trazar una autoescala. La inteligencia artificial utilizada para hacer estas determinaciones no es a prueba de fallas. Las opciones de paleta y de autoescala pueden ser rápidamente corregidas en el diálogo Layer Properties (Propiedades de las Capas) si es necesario. La función de visualización automática está diseñada como una utilidad de vista rápida, no como un sustituto del Iniciador de Visualización.

## Cómo Abrir Mapas y Capas desde el Explorador de Archivos de IDRISI

Notará que el Explorador de Archivos de IDRISI (File Explorer) tiene una serie de opciones de visualización. La acción por defecto es ver el archivo como una interpretación gráfica en una ventana de mapa. Esto utiliza la función de visualización automática para mostrar cualquier capa de datos o composición de mapa de la lista. Sin embargo, debe advertirse que la visualización automática posee información limitada acerca de la capa, y por eso puede que no produzca la mejor apariencia de visualización. Nuevamente, esto sólo está diseñado como una utilidad de vista rápida y no como un sustituto para el Iniciador de Visualización. Las composiciones de mapas visualizadas desde el Explorador de Archivos de IDRISI se muestran exactamente como han sido guardadas, ya que toda la información de los archivos de paleta y símbolos está incluida en el archivo del mapa.

## Ventanas de los Mapas y Marcos de las Capas

Una capa de mapa se muestra en un *Marco de la Capa* (Layer Frame). Éste y todos los demás componentes de la composición cartográfica (Ej.: flecha norte, leyenda) están ubicados en las *Ventanas de Mapas* (Map Windows). Una sola Ventana de Mapas incluye un solo Marco de Capa. El resto de los componentes que pueden estar en una Ventana de Mapa se describen abajo en la sección sobre Propiedades de los Mapas. La Ventana de Mapas puede pensarse como la “página” gráfica sobre la cual se monta una composición de un mapa. Su color se establece en el diálogo Propiedades de los Mapas y su tamaño puede ser maximizado o modificado interactivamente colocando el cursor sobre el borde de la ventana hasta que cambie a una flecha doble, luego se lo arrastra hacia la posición deseada.

Un marco de capa puede moverse haciendo doble clic sobre éste (verá que luego aparece un conjunto de botones para modificar el tamaño) y luego arrastrándolo a su nueva posición.<sup>27</sup> También se le puede modificar el tamaño sosteniendo uno de los botones de tamaño visibles y moviendo el borde del marco de la capa. En cualquier caso (movimiento o modificación de tamaño), la acción será completada al hacer clic sobre cualquier otro componente del mapa o sobre la barra del nombre de la ventana del mapa. Esto hará que los botones de tamaño desaparezcan y que las capas vuelvan a su tamaño original (preservando el radio del aspecto original) para encajar dentro del marco de la capa.

Observe que hay varios botones de la barra de herramientas (Toolbar) útiles para realizar manipular los marcos de las capas. Éstos se muestran en la siguiente tabla. El primero de ellos hace que el marco de la capa se cierre alrededor de las capas actualmente visualizadas. Esto es particularmente útil luego de modificar el tamaño, cuando el nuevo marco de capa no posee exactamente la forma correcta para sostener las capas. El segundo expande la ventana

<sup>27</sup> Para arrastrar un componente, coloque el cursor sobre el componente (no sobre los botones de tamaño) y sostenga el botón izquierdo del mouse apretado mientras mueve el cursor hacia la posición deseada. “Deja” el componente en el lugar soltando el botón del mouse.

de mapas y el marco de capas tanto como sea posible mientras se mantengan totalmente visibles (el botón también puede ser activado presionando la tecla Fin). Observe que al hacer esto, el sistema reserva espacio para el Diseñador. Si desea ignorar el Diseñador, sostenga la tecla Mayús (o Shift) mientras aprieta la tecla Fin. El tercer botón regresa la ventana de mapas y el marco de capas a su estado de visualización inicial. Esta acción también puede activarse presionando la tecla Inicio.

Icono de la Barra de Herramientas	Teclado	Acción
		Coloca la Ventana de Mapas en el Marco de Capas
	FIN	(deja espacio para el Diseñador)
	SHIFT + FIN	Maximiza la Visualización del Marco de Capas (ignora el Diseñador)
	INICIO	Reestablece la Ventana Original

## Diseñador (Composer)

Tan pronto como se abre la primera ventana de mapa de IDRISI, aparece sobre la pantalla el cuadro de diálogo del Diseñador. El Diseñador puede considerarse como un asistente cartográfico que nos permite:

- Agregar o remover capas de la composición;
- Cambiar el orden en el que se dibujan las capas (llamado la prioridad de una capa);
- Establecer una capa para que sea parte de un compuesto de colores;
- Establecer una capa para que tenga un fondo transparente o se mezcle con la capa debajo de ésta.
- Ajustar temporariamente una capa para que sea invisible (es decir, esconderla) sin removerla por completo;
- Examinar y alterar las propiedades de una capa, incluyendo el archivo de paleta o de símbolos en uso, los puntos de saturación de la visualización, y la autoescala;
- Agregar, borrar y modificar una variedad de componentes de mapas en la ventana de mapas;
- Activar el cursor en Modo de Consultas (Inquiry) para examinar las propiedades de las características de cualquier capa;
- Guardar la composición actual (como se visualiza) como un archivo de MAPA; e
- Imprimir la composición



Si tiene varias ventanas de mapas abiertas, notará que el Diseñador muestra la información para la ventana del mapa que tiene *foco* (o para la última que haya recibido foco si una ventana de mapa, tal como un cuadro de diálogo u otra ventana, tiene foco en el momento). El foco se refiere a la habilidad de una ventana para recibir mensajes de entrada desde el mouse o del teclado. Windows designa la ventana que tiene foco mostrando su barra con un color específico.<sup>28</sup> Para poner una ventana en foco, cliquee sobre cualquier parte de la misma. Para cambiar las características de una composición de mapa particular, primero hay que darle foco.

<sup>28</sup> Esta es solo una de las varias configuraciones en el sistema de visualización Windows que se definen cuando se elige una combinación de colores o cuando se definen las características de visualización de los componentes individuales de Windows.

## Agregar una Capa

Para agregar una capa, cliquee el botón Add Layer<sup>29</sup> del Diseñador y elija el archivo deseado.<sup>30</sup> Luego se le presentará un diálogo similar para indicar el archivo de paleta o de símbolos que debe usarse y si se le debe trazar una autoescala a la nueva capa. Todas las capas en una composición de mapa deben compartir un sistema de referencia común. Si este no es el caso, aparecerá un mensaje de advertencia indicando este problema y advirtiéndole que la capa no se visualiza correctamente. Los límites o bordes de los archivos no necesitan coincidir para ser visualizadas juntas en una composición de mapa.

Cuando se agrega una nueva capa, se le da automáticamente la prioridad más alta (es decir, se coloca por encima de las demás capas). Entonces, la primera capa visualizada, por defecto, tendrá la prioridad más baja (prioridad 0) y se colocará en la parte inferior de la composición. La capa con prioridad 0 a menudo se la llama la *capa base* en este documento.

Cuando hay múltiples capas, la prioridad de estas puede ser cambiada arrastrando el nombre de la capa de interés, y soltándola en la posición deseada. Siempre que una ventana de mapa es reposicionada, las capas se posicionan en su orden de prioridad, comenzando con 0 y aumentando hasta el valor más alto.

Observe que si se agrega una capa raster, ésta oscurecerá todas las capas que se encuentran por debajo a menos que se le designe un fondo transparente o se mezcle con las capas de abajo (ver la próxima sección para más detalles).

## Organizador Automático (Auto-Arrange)

La función del Organizador Automático ordena automáticamente los elementos del mapa tales como títulos, leyendas, barra de escalas y textos. Esta función se encuentra activada por defecto en toda ventana con mapas pero puede desactivarse para permitir la ubicación manual de los elementos para una composición de mapas. Esto resulta muy útil en impresiones.


Cuando función del Organizador Automático está activada y siempre que se actualice el tamaño de la ventana del mapa, todos los elementos del mapa de esa ventana serán reubicados en relación a su ubicación original en la fotografía de la superficie.

## Botones de Interacción de las Capas

Inmediatamente arriba del botón Agregar Capa hay un grupo de botones que controlan los efectos de interacción de capas. El primero desde la izquierda es el botón Blend (mezclar). Si la capa resaltada es raster, al presionar este botón la capa se mezclará en un 50% con el grupo de capas visibles debajo de ésta. Para eliminar el efecto de mezcla, debe resaltar o activar la capa fusionada y cliquee este botón nuevamente. El primer botón desde la



derecha es el de Transparency (transparencia). Si la capa resaltada es raster, al presionar este botón hará que el color del fondo (cualquiera sea el color 0 en la paleta) se vuelva transparente. Observe que las capas pueden estar fusionadas y ser transparente al mismo tiempo como se muestra abajo.



<sup>29</sup> Alternativamente, al presionar Ctrl.-R cuando una ventana de mapa tiene foco, se abrirá el cuadro de diálogo Agregar Capa (Add Layer) para agregar una capa raster. Y al presionar Ctrl.-V, se abrirá el cuadro de diálogo Agregar Capa para agregar una capa vectorial.

<sup>30</sup> Un sólo marco de capas está presente en cualquier ventana de mapas; por lo tanto, todas las capas se agregan al mismo marco de capas. Observe que las capas pueden ser agregadas desde varias rutas para su visualización. No obstante, si la composición se va a almacenar como archivo de composición de mapas, todas las capas deben existir en la Carpeta de Trabajo y/o Carpeta de Recursos del proyecto desde el cual se visualizará nuevamente la composición.

Esta secuencia muestra una capa con un sombreado de colinas y un modelo de elevación digital que está siendo fusionado (tercer marco). En el cuarto marco, se ha agregado una capa máscara con el negro como color 0 y el gris como color 1. En el quinto marco, la máscara es transparente permitiendo mostrar el modelo de elevación a través del color del fondo. Finalmente, en el último marco, la máscara también está establecida para fusionarse, y así permitir que la topografía sea parcialmente visible a través de la máscara gris.

El resto de los botones sirven para crear diversos compuestos de colores. Los botones Rojo, Verde y Azul permiten designar capas como los componentes primarios rojo, verde y azul de una imagen a todo color. Observe que las



necesitan ser adyacentes para que esto funcione, no obstante el orden específico no es importante. El botón Cyan (el segundo desde la izquierda) se usa para crear tres anaglíficos tridimensionales. La creación de un anaglífico requiere imágenes estéreo – dos vistas del mismo paisaje tomadas desde diferentes ubicaciones, y un par de anteojos 3-D para anaglíficos. Cuando estas son superpuestas usando Add Layer (agregar capa), asigne el color primario rojo a la vista



izquierda y el color primario cyan a la vista derecha (este orden puede necesitar revertirse dependiendo de sus anteojos). Nuevamente, las capas deben estar una junto a la otra en su orden de prioridad para que esto funcione.

## Eliminar una Capa

Para eliminar una capa, seleccione su nombre de la lista de capas que se muestra en el Diseñador y luego haga clic en el botón Remove Layer (eliminar capa). Si sólo desea esconder la capa temporalmente, no la elimine, sino cambie su visibilidad.

## Visibilidad, Tipos y Nombres de las Capas

El Diseñador muestra una fila por cada capa en la composición. Ud. puede poner una capa visible o invisible al hacer clic en el botón a la izquierda de su nombre. Observe que el poner una capa en off (desactivarla) no la elimina de la composición.

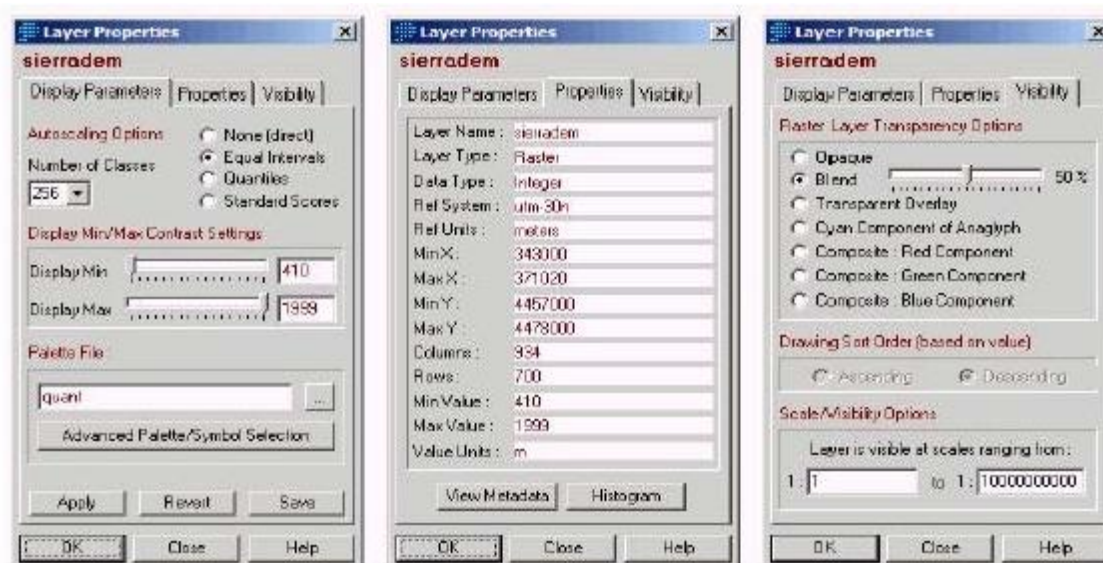
En cambio, sólo la esconde temporalmente. En algunos casos, esto puede facilitar en gran medida el análisis visual.

A la derecha del nombre de la capa hay un símbolo gráfico que indica el tipo de capa: raster, vectorial de puntos, vectorial e líneas, vectorial de polígonos o vectorial de texto. Estos tipos se ilustran abajo. Esta información se utiliza, por ejemplo, para indicar qué archivo es cual cuando una capa raster o vectorial se encuentran en la misma composición.

	Tipo de Capa	Icono del Diseñador
	Raster	
	Vectorial de Puntos	
	Vectorial de Líneas	
	Vectorial de Polígonos	

## Propiedades de las Capas

Las propiedades de cualquier capa, incluyendo la información de documentación clave y los parámetros de visualización, se muestran en el diálogo Layer Properties (Propiedades de las Capas). Para ver esto, resalte la capa de interés con un solo clic sobre el nombre de la capa en el Diseñador, y luego haga un clic en el botón Layer Properties. Esto mostrará el diálogo Layer Properties asociado con esa capa.



El diálogo Layer Properties resume varios elementos importantes del archivo de documentación de la capa organizados en tres fichas. La primera ficha permite cambiar la forma en que se ha trazado la escala en la imagen para su visualización incluyendo el número de clases y el esquema de clasificación. Además, permite cambiar el contraste de la imagen si se le ha trazado la autoescala usando Intervalos Iguales. Esta ficha también permite cambiar el archivo de paleta o de símbolos y da acceso a la página de Selección Avanzada de Paleta/Símbolo (ver la sección sobre el Iniciador de Visualización).

La segunda ficha resalta las propiedades claves y ofrece la opción de acceder a la utilidad Metadata desde la cual se pueden ver y alterar todos los valores de los archivos de documentación. Si es una capa raster, puede abrirse un histograma de la capa usando el botón Histogram (Histograma). Si la capa es un archivo vectorial de definición de características asociado a un campo de tabla de atributos, puede mostrarse la tabla de datos completa usando el botón Access Table (Acceder a la Tabla).

La tercera ficha accede a las propiedades de visibilidad, incluyendo la habilidad para establecer mezclas específicas además de aquellas del 50% que se dan por defecto y son accesibles desde el botón Blend (Mezclar) del Diseñador. El orden de diseño afecta las capas vectoriales solamente y controla el orden en que se dibujan las características vectoriales. Esto se utiliza para establecer la prioridad visual apropiada cuando las características vectoriales se superponen. Este diálogo también permite establecer a qué escala es visible la capa. Mientras Ud. aumenta o achica la imagen, las capas se desactivarán si la escala queda fuera del rango visible.

### Cambiando los Puntos de Saturación de Visualización Mín. / Visualización Máx.

Cuando la autoescala de Intervalos Iguales está activa, todos los valores menores que o iguales a la visualización mín. que han sido grabados en el archivo de documentación serán asignados al símbolo o color de paleta más bajo en la secuencia. De manera similar, todos los valores mayores que o iguales a la visualización máxima serán asignados al símbolo o color de paleta más alto en la secuencia.<sup>31</sup> Es por esta razón que estos valores se conocen como puntos de saturación. Al ajustarlos, se altera el brillo y el contraste de la imagen.

<sup>31</sup> Observe que los símbolos y colores más bajos y más altos en la secuencia son aquellos establecidos como la autoescala mín. y máx. en el archivo de símbolos o paleta. Éstos pueden ajustarse en el Taller para Símbolos.



Existen dos opciones para cambiar estos valores dentro del diálogo Layer Properties. Pueden editarse con los cuadros de entrada apropiados, o pueden ajustarse por medio de los deslizadores (sliders). Éstos pueden moverse arrastrándolos con el mouse, o haciendo clic sobre el deslizador particular y luego presionando la tecla de dirección de la izquierda o la de la derecha. Las teclas de flechas mueven el deslizador por incrementos muy pequeños ocasionados por defecto, sin embargo producirán movimientos más grandes si se presiona la tecla Mayús al mismo tiempo.<sup>32</sup>

La mejor forma de familiarizarse con los efectos del cambio de los puntos de saturación es experimentarlo. En general, al mover los puntos de saturación hacia el centro desde sus correspondientes valores de datos mínimos y máximos se aumentará el contraste. En realidad, Ud. sacrifica los detalles de los bordes de la distribución para aumentar la visibilidad de los detalles en el resto de la misma. Si la imagen parece demasiado oscura en general, pruebe mover hacia abajo la visualización máx. (display max). De la misma manera, si la imagen parece demasiado brillante, mueva la visualización mín. (display min) hacia arriba. Dependiendo de la distribución de los valores de datos originales (la cual puede medirse con el HISTO), ajustar interactivamente los puntos de saturación y observar los efectos puede ser muy útil en el análisis visual de imágenes. Este es particularmente el caso con imágenes compuestas a color de 24 bits.

## Propiedades de los Mapas



Mientras que el diálogo Layer Properties muestra información acerca de una sola capa de mapa, el diálogo Map Properties (Propiedades de los Mapas) describe la composición entera del mapa. Se usa para establecer la visibilidad y las características de los componentes de los mapas tales como las leyendas de las capas, la flecha norte, etc.

El diálogo Map Properties puede ser abierto haciendo clic en el botón Map Properties del Diseñador (Composer) o haciendo clic en el botón derecho del mouse sobre una ventana de mapa. El método del clic del mouse es sensible al contexto. Por ejemplo, un clic derecho del mouse sobre una leyenda abre el diálogo Map Properties con las opciones de leyenda visibles.

Map Properties es un diálogo formado por fichas. Simplemente hay que clicar sobre la ficha apropiada para acceder a las opciones asociadas con un componente de mapa particular. Éste brinda diez fichas: Legends (Leyendas), Georeferencing (Georeferenciamiento), Map Grid (Grilla de Mapas), North Arrow (Flecha Norte), Scale Bar (Barra de Escala), Text Inset (Insertar Textos), Graphic Insets (Insertar Gráficos), Titles (Títulos), Background (Fondo) y Placemarks (Marcas de Lugar). Las opciones para cada una se describen a continuación.

La Ventana de Mapas (Map Window) se puede agrandar en cualquier momento para aumentar el tamaño de su página gráfica y hacer espacio para nuevos componentes del mapa. En todos los casos, los componentes deben establecerse en Visible para ser visualizados. Todos los componentes son movibles y a muchos pueden se les puede modificar el tamaño interactivamente. Para hacer esto, haga doble clic sobre el componente, introduzca los cambios necesarios y luego cliquee cualquier otro elemento para abandonar el modo mover/modificar tamaño (move/resize).

<sup>32</sup> Si Ud. siempre desea visualizar una capa con valores particulares de visualización mín. y máx. que no son los valores mín. y máx. reales de la capa, use el Metadata para establecer los campos de visualización mín. y máx. del archivo de documentación de la capa con los valores deseados. Siempre que se visualiza el archivo, se usarán estos valores para establecer el rango de valores cubiertos por el archivo de paleta o símbolos. Los valores reales de los datos se mantienen sin cambios.

## Leyendas (Legends)

Hasta cinco capas pueden mostrar leyendas en una composición de mapa. Cualquier capa raster o vectorial de punto, línea o polígono puede tener una leyenda. Las entradas para los textos de leyendas son almacenadas en los archivos de documentación de la capa y pueden ser llenadas o modificadas con la utilidad Metadata. Se permiten hasta 256 entradas. Por defecto, la leyenda mostrará hasta 20 categorías (esto puede cambiarse en las Preferencias de Usuario del menú Archivo). Sin embargo, siempre que hay más de 20 entradas de leyendas en el archivo de documentación, se adjunta a la leyenda una barra vertical de desplazamiento para que Ud. pueda desplazarse entre las entradas restantes.

Para una capa de datos cuantitativa con datos de tipo entero y byte y con un rango de valores de 20 o menos, se formará automáticamente una leyenda y se le dará título (es decir, no se necesitan entradas para leyendas en el archivo de documentación). Si los datos son reales o si el rango de datos es mayor de 20, se mostrará una especial leyenda continua y se generarán automáticamente títulos representativos de las categorías.

## Georeferenciamiento (Georeferencing)

La ficha Georeferenciamiento muestra el sistema y las unidades de referencia de la composición actual, así como también su rectángulo delimitante. Además muestra el rectángulo delimitante real de todas las características de la composición. El sistema y las unidades de referencia pueden cambiarse usando los cuadros de entrada brindados. Por otra parte, se ofrece un botón para permitir establecer el rectángulo delimitante de la composición dentro de los bordes o límites de las características actuales.

La ficha Georeferenciamiento también se utiliza para establecer una propiedad muy importante relacionada con las capas de texto vectoriales. Los tamaños de los textos se determinan en *puntos* – una medida de impresión tradicional igual a 1/72 pulgadas (0,025/1,82 m). No obstante, en el dinámico ambiente de un SIG, donde uno amplifica y reduce constantemente (y cambia las escalas), puede ser más útil relacionar el tamaño del punto con las unidades del suelo. La opción Convert Text Point Sized to Map Reference Units (Convertir Textos en Tamaño de Puntos a Unidades de Referencia de Mapa) de la ficha Georeferencing lleva a cabo esta tarea. Cuando esta opción está activada, las leyendas de textos asociadas con las capas de texto (pero no los componentes del mapa como los títulos) cambiarán de tamaño cuando se aplique el zoom, como si el texto estuviese adherido al paisaje. La relación de escala entre el tamaño del punto y las unidades de referencia del mapa también es definida por el usuario. Cuando esta opción está desactivada, las leyendas de textos retienen su tamaño original cuando se aplica el zoom a las capas.

## Grilla del Mapa (Map Grid)

Una grilla del mapa puede colocarse sobre el marco de la capa. Los intervalos pueden especificarse como también los valores de inicio de X e Y (todos en las unidades de referencia). Además se puede elegir el color y el ancho de las líneas de la grilla y de la fuente del título. La grilla se titula en forma automática.

## Flecha Norte (North Arrow)

Una flecha norte puede ser agregada a la composición. Ud. establece la declinación de la flecha y puede especificar cualquier texto para que sea visualizado a la derecha o a la izquierda de la misma. Esto le permitirá, por ejemplo, cambiar el texto a “Norte Magnético” en lugar de “Grilla Magnética”, o cambiarlo a un idioma diferente.

## Barra de Escala (Scale Bar)

Agregar una barra de escala puede realizarse con el diálogo Map Properties. Ud. establece la longitud (en las unidades del sistema de referencia de un mapa), el número de divisiones, las propiedades de los colores y el nombre de la barra de escala. La barra de escala ajusta automáticamente su ancho mientras se aplica un zoom.<sup>33</sup>

## Insertar Textos (Text Inset)

La inserción de textos puede usarse para mostrar bloques de textos. Esto se realiza especificando el nombre de un archivo de texto ASCII. El tamaño del marco de la inserción de textos se puede modificar, además éste incorpora retorno automático de palabras. También se puede determinar el estilo de la fuente y el color del fondo.

## Insertar Gráficos (Graphic Insets)

Las inserciones de gráficos pueden utilizarse para guardar inserciones de mapas, dibujos, logotipos o cualquier otra imagen gráfica. Cualquier Windows Bitmap (“.bmp”) o Metafile (“.wmf” o “.emf”) puede usarse como inserciones para gráficos. A todas las inserciones de gráficos se les puede modificar el tamaño. Sin embargo, si la opción

<sup>33</sup> A veces esto puede resultar una molestia ya que la barra de escala puede necesitar expandirse para ser mayor que el ancho de la ventana del mapa. En estos casos, simplemente coloque su visibilidad en “off” usando Map Properties. De lo contrario, use Map Properties para configurar el tamaño de la barra de escala a una longitud menor.



Stretchable (extensible) está desactivada, la modificación del tamaño es controlada para preservar el aspecto original del radio de la inserción.

## Títulos (Titles)

Un título, subtítulo o leyenda puede ser agregado a una composición de mapa. Éstos no están asociados con ninguna capa de mapa en particular, sino que pertenecen a una composición de mapa en su totalidad. No obstante, el título de la capa de base, leído desde su archivo de documentación, aparecerá como el texto del título por defecto. Esto se puede editar y las propiedades de la fuente se pueden determinar.

## Fondo (Background)

La ficha Background permite cambiar el color del fondo del Marco de la Capa y de la Ventana del Mapa. Los fondos de los demás componentes, como las leyendas y la barra de escala, se determinan en sus respectivas fichas. Sin embargo, la ficha Background también permite establecer los fondos de todos los componentes para que coincida con el de la Ventana del Mapa. Observe que la especificación el fondo del marco de la capa puede no ser visible si una capa raster está presente en la composición (ya que ésta puede cubrir el marco entero). También advierta que existe un color de fondo por defecto que se determina con las Preferencias de Usuario en el menú Archivo.

## Marcas de Lugar (Placemarks)

Finalmente, la ficha Placemarks hace un seguimiento de las marcas de lugares asociadas con la composición del mapa. Una marca de lugar es una ventana particular de las capas del mapa. La ficha Placemarks permite definir nuevas marcas de lugares, borra las existentes y dirigirse a cualquiera en específico. Las marcas de lugares se describen en detalle más adelante en la sección sobre las Características de la Visualización Interactiva.

## Propiedades de las Características

El botón Feature Properties (Propiedades de las Características) del Diseñador activa el cursor en modo Feature Properties, el cual abre una tabla de propiedades asociadas con las características identificadas con el mouse. Este modo también puede activarse con el icono Feature Properties de la barra de herramientas. Vea la sección siguiente sobre las Características de Visualización Interactiva para obtener una descripción completa.

## Cómo Guardar la Composición

En cualquier momento mientras se usa el Diseñador, es posible guardar la composición del mapa en varios formatos. El botón Save Composition (Guardar la Composición) abre un diálogo que presenta las opciones de formato. La primera consiste en guardar la composición del mapa como un archivo MAP. Un archivo MAP contiene un registro completo de la composición en un archivo con extensión “.map”.<sup>34</sup> Este puede visualizarse en cualquier momento iniciando el Display Launcher e indicando que desea visualizar un archivo de composición de mapa. Con esta forma de almacenamiento de la composición es posible restaurarla a su estado exacto anterior, y luego continuar con el proceso de composición.

Las próximas tres opciones permiten guardar la composición en formato de archivo gráfico BMP, WMF o EMF. Estos tipos de archivos se usan para autoediciones, hojas de cálculo y programas software de procesadores de textos. El BMP es el bitmap raster, producido con el simple copiado de la pantalla. A menudo se lo llama *depósito de pantalla*, porque copia la apariencia exacta de la ventana del mapa, sin copiar los detalles de cómo se formó la composición (es decir, los nombres de las capas, su simbolización, etc). El formato WMF es la estructura “Windows Metafile” usada en Windows 3.1. Éste guarda las instrucciones de Windows que pueden usarse para reconstruir tanto elementos raster como vectoriales de la ventana de mapa. Éstos luego pueden importarse en un programa de gráficos o de publicaciones de escritorio. El formato EMF es la estructura más nueva de “Metafile Mejorado” de Windows. Éste es una continuación de la estructura WMF, y está específicamente diseñado para las variantes de 32 bits de Windows (95, 98/ME, NT, 2000, XP). Siempre que exista la opción entre WMF y EMF, elija el formato EMF.

---

<sup>34</sup> Se puede hallar más información sobre la estructura de los archivos MAP en el capítulo **Capas de los Mapas, Colecciones y Estructuras de los Datos**. Advierta que el archivo MAP contiene las instrucciones para construir la composición del mapa, pero no incluye las capas de datos del mapa. Estos archivos separados se usan para recrear la composición.

La próxima opción copia la ventana del mapa en el portapapeles de Windows en lugar de copiarla en un archivo. Esto facilita copiar las composiciones inmediatamente en otros programas software.

Finalmente, la última opción permite almacenar la región de la capa activa que actualmente aparece en la ventana como una nueva capa IDRISI. Si es una capa raster, solo la porción de la imagen raster que se visualiza en ese momento será escrita en el nuevo archivo raster. Esto es entonces una versión interactiva del módulo Windows (Ventana). Sin embargo, si la capa activa es vectorial, se copiará el archivo entero, pero las coordenadas comprometidas serán alteradas para coincidir con la ventana actual. El nuevo archivo visualizará la región de la ventana, pero todos los datos originales fuera de esa ventana todavía existen en el archivo.

## Cómo Imprimir la Composición

Para imprimir una composición de mapa, primero hay que abrirla. Asegúrese de que la ventana del mapa tiene foco o está activa, luego haga clic en el botón Print Composition (Imprimir la Composición) del Diseñador. En el diálogo Print Composition, se puede seleccionar la impresora deseada, acceder a las opciones de configuración, elegir ubicar la ventana del mapa tan grande como sea posible sobre la página o imprimirla de acuerdo a la escala especificada por el usuario. Los márgenes de página pueden configurarse y se le puede trazar una escala al ancho de las líneas. Se muestra una vista preliminar de la página para ver como va a quedar la impresión. Todos los dispositivos de impresión compatibles con Windows son aceptados.

## Navegación

En la parte inferior del Diseñador hay varios botones pequeños de navegación. Éstos permiten realizar un paneo (moverse) hacia la izquierda, derecha, hacia arriba y abajo, y también permiten aumentar o reducir la imagen. Estos botones se describen más adelante en este capítulo en la sección sobre Características de la Visualización Interactiva.

## Taller para Símbolos



Las capas de mapas en una composición son creadas por medio de archivos de símbolos y de paleta. Mientras que en IDRISI se incluye un juego de archivos de símbolos, por lo general Ud. va a querer desarrollar archivos de símbolos específicos para optimizar el impacto de la información presentada en sus mapas finales

Los archivos de símbolos y de paleta se crean y se modifican usando el Taller para Símbolos<sup>35</sup> disponible en el menú Archivo (File) y a través de los iconos de la barra de herramientas. En total, se pueden crear cinco tipos de archivos: archivos de símbolos de puntos, archivos de símbolos de líneas, archivos de símbolos de polígonos, archivos de símbolos de texto y archivos de paletas. Los archivos de símbolos graban las interpretaciones gráficas para hasta 256 símbolos, indexados del 0 al 255. Por ejemplo, un archivo de símbolos de textos puede indicar que las características a las que se le asignó un índice 5 de símbolo tienen sus nombres escritos en texto color rojo con fuente Times New Roman negrita, cursiva, tamaño 10.

En el menú Symbol Workshop File (Archivo del Taller para Símbolos) se puede optar por abrir un archivo existente o crear uno nuevo. Si opta por la segunda opción, necesitará indicar el tipo de símbolo: punto, línea, polígono, texto o paleta. Los 256 símbolos luego son desplegados en una grilla de 16 x 16. Para cambiar un símbolo, simplemente haga clic en la celda de la grilla con ese símbolo. Un diálogo de símbolo específico aparece luego, permitiendo alterar cualquiera de las siguientes configuraciones:

Tipo de Archivo de Símbolos	Atributo
Símbolos de Puntos	Tipo de Símbolos Estilo de Relleno Tamaño Color de Relleno Color del Borde
Símbolos de Líneas	Estilo de Línea Ancho de Línea Color

<sup>35</sup> IDRISI para Windows tenía una utilidad separada llamada Taller para Paletas para la manipulación de paletas. Esta ha sido incorporada en el Taller para Símbolos.

Símbolos de Polígonos	Estilo de Relleno Color
Símbolos de Textos	Fuente Tamaño Color Estilo (normal, negrita, cursiva, subrayado)
Paleta	Color

Una característica muy importante del Taller para Símbolos es la habilidad para copiar o mezclar atributos. Por ejemplo, imagínese crear un archivo de símbolos de puntos de círculos graduados. Haga clic sobre el símbolo 0 y determine sus propiedades para producir un círculo muy pequeño de color amarillo. Luego diríjase al símbolo 255 y establezca un círculo grande color rojo. Ahora configure los puntos terminales de la mezcla en 0 y 255 y cliquee el botón blend (mezclar). Tendrá ahora una secuencia de círculos que cambian suavemente en color y tamaño.

Como acompañante de la opción blend, el Taller para Símbolos también brinda una función de copiado (copy). Con ambas funciones, mezcla y copiado, es posible configurar las opciones que harán que sólo se copien o mezclen atributos específicos (como el tamaño o el color). Para obtener un panorama de cómo se verán los símbolos sobre un fondo particular, se puede establecer un color de fondo para la visualización del Taller para Símbolos.

Finalmente, el rango de autoescala de un archivo de símbolos puede especificarse o alterarse en el Taller para Símbolos. Todos los archivos de símbolos contienen definiciones para 256 símbolos. Sin embargo, al alterar el rango de la autoescala, es posible crear secuencias de un rango más limitado. Por ejemplo, para establecer una paleta con 8 colores, hay que configurar el mín. y el máx. de la autoescala en 0 y 7 respectivamente. Luego hay que definir estos 8 colores. En la práctica, resultará que la paleta tiene solo 8 colores si a la capa con la cual se utiliza se le ha trazado una autoescala.

## Reproductor Multimedia (Media Viewer)

El Reproductor Multimedia es una utilidad para crear y visualizar imágenes de video compuestas por una serie de imágenes de IDRISI. El Reproductor Multimedia se encuentra en el menú Display. Cuando está activado, presenta el diálogo básico de control con su propio menú. Haga clic sobre el menú File para crear un nuevo video o para abrir uno existente. Si elige crear un video nuevo, se le presentará un diálogo nuevo que requiere el nombre del archivo Grupo Raster (“rfg”) o del archivo Serie de Tiempo (“ts”) que define las imágenes que serán usadas y su orden en el video.

También se pide especificar una paleta (Palette) para ser usada y el tiempo de demora entre las imágenes sucesivas. El resultado de la operación va a ser un archivo de video multimedia “.avi” que puede visualizarse en cualquier momento utilizando los controles del Reproductor Multimedia. Observe que se le puede modificar el tamaño al reproductor arrastrando sus bordes. El tamaño de la imagen se puede configurar para que se ajuste al tamaño del reproductor seleccionando la opción Fit to Window (Ajustar a la Ventana) en el menú Properties. Además, se puede colocar un video en repetición continua.

## Características de Visualización Interactiva

Una de las características destacadas de los SIG es que las visualizaciones de los mapas no son estáticas. Al contrario, éstas proveen un medio altamente interactivo para la exploración de datos de mapas. IDRISI incluye un número de características que forman la base para esta interacción.

### Movimiento y Modificación del Tamaño

Como se dijo anteriormente, todos los componentes de mapas (marco de capa, título, leyenda, etc.) pueden moverse, y la mayoría también puede modificar su tamaño. El movimiento se logra colocando el cursor sobre el componente en cuestión, haciendo doble clic para cambiar a modo move/resize (movimiento/modificación del tamaño), y luego presionando el botón izquierdo del mouse para arrastrar el elemento hacia su nueva ubicación. Para salir del modo move/resize hay que hacer clic sobre cualquier otro componente o sobre la barra de la ventana del mapa. Dentro del modo move/resize, la modificación del tamaño se logra arrastrando uno de los botones de modificación del tamaño ubicados en los márgenes del componente.

## Cursor en Modo Consultas



Mientras se mueve el cursor sobre la ventana de un mapa, la barra de estado en la parte inferior de la pantalla indica las coordenadas X e Y del cursor en el sistema de referencia geográfica (para capas raster, la posición columna/fila también se muestra). Se puede averiguar *qué* hay en esa ubicación usando el Cursor en Modo Consultas (Cursor Inquiry Mode). Para activar este modo del cursor, presione este botón en la barra de herramientas (Toolbar). El botón se verá como oprimido. Cuando este modo está activo, se puede consultar el valor en cualquier posición de la capa activa de cualquier ventana de mapa. En el caso de una capa raster, el cursor mostrará el valor numérico y la interpretación de la leyenda (si existe una) de la celda en la grilla. Para una capa vectorial, el cursor mostrará el valor numérico y la interpretación de la leyenda de la característica más cercana. Advierta en particular que cuando una ventana de mapa contiene varias capas, el valor visualizado corresponde a la capa activa (la que está resaltada en el Diseñador). La capa activa puede cambiarse fácilmente haciendo clic sobre el nombre de la capa deseada en la lista del Diseñador. El modo Consultas del cursor puede permanecer activo, pero es mejor que lo desactive si desea mover o modificar el tamaño de los componentes. Para hacer esto, simplemente haga clic sobre el botón Cursor Inquiry nuevamente.


## Propiedades de las Características



El cursor en modo Consultas (Inquiry) permite ver los valores de las características de una sola capa por vez. Para las capas que son miembros de una colección, la opción Feature Properties permite observar una vista simple tabular de los valores de todos los miembros de la colección en la ubicación de la consulta. Para activar esta función, haga clic en el botón Feature Properties del Diseñador o de la barra de herramientas. Para desactivarla, haga clic nuevamente en el botón.

Para que el modo de consultas de multi-capas funcione, la capa tiene que haber sido desplegada o agregada en la ventana del mapa como parte de una colección. Esto se logra tipeando el nombre de la capa con “dot logic” descrita en el capítulo Capas de Mapas, Colecciones y Estructuras de los Datos de este volumen, o eligiendo el nombre de la capa desde la lista de miembros que se encuentra bajo el nombre de archivo de la colección en la lista de selección (pick list). Cuando Feature Properties se usa con capas que no son miembros de un grupo, se presenta información simple relacionada con la capa en la tabla de Feature Properties junto con el valor y la posición de la ubicación consultada.

Evidentemente la mejor ventaja de la tabla de Feature Properties es que se pueden ver los valores de todos los miembros del grupo al mismo tiempo. Además, ésta puede desplegar los valores como un gráfico. Observe que también se ofrecen controles para cambiar la posición de la línea separadora (separator line) en modo tabla. Para desactivar el modo Feature Properties, haga nuevamente clic en el botón Feature Properties o en su correspondiente icono de la barra de herramientas. El modo Consultas del cursor se activa automáticamente cada vez que se activa la función Feature Properties.



## Paneo y Zoom

El pan o paneo y el zoom permiten navegar alrededor de la imagen en escalas variantes (magnificaciones). El método más simple de paneo y de zoom es usar los botones especiales que se encuentran en la parte inferior del Diseñador, aunque también se puede usar el teclado. Las funciones se resumen en la tabla a continuación. La manera más fácil para entender las acciones de estas teclas es imaginarse a bordo de un avión. Cuando aplica una ampliación (zoom in), su altitud disminuye mientras que su escala aumenta (es decir, Ud. ve un área menor pero con más detalles). De forma similar, cuando aplica una reducción (zoom out) su altitud aumenta y su escala disminuye (es decir, Ud. verá más pero con menos detalles). La fracción representativa (RF) de la barra de estado cambia mientras Ud. aplica un zoom, ya sea para amplificar o reducir la imagen. Una lógica similar está asociada con las teclas de dirección. Al presionar la tecla con la flecha de la derecha, su avión imaginario se mueve hacia la derecha mientras que la imagen parece moverse hacia la izquierda.

Botón del Diseñador	Teclado	Acción
	Flecha Izquierda	Paneo hacia la izquierda
	Flecha Derecha	Paneo hacia la derecha
	Flecha Superior	Paneo hacia arriba
	Flecha Inferior	Paneo hacia abajo
	RePág o PgDn	Amplificación
	AvPág o PgUp	Reducción

Icono de la Barra de Herramientas	Teclado	Acción
		Zoom Window
	INICIO	Restore Original Window

Además de estas opciones continuas de zoom y paneo, la barra de herramientas también ofrece una ventana de zoom. Esta función permite dibujar un rectángulo alrededor del área en la que desea aplicar un zoom. Para hacer esto, haga clic en el botón Zoom Window (que se muestra a continuación) y mueva el cursor hacia cualquier esquina del área seleccionada. Luego presione el botón izquierdo y arrastre el rectángulo hacia la esquina diagonalmente opuesta a aquella con la que comenzó. Cuando suelte el botón izquierdo del mouse, el zoom se habrá aplicado. El botón Restore Original Window (Restaurar la Ventana Original) de la barra de herramientas o la tecla Inicio restituye la ventana del mapa y el marco de la capa a su tamaño original.

Todas las operaciones de zoom y paneo ocurren dentro del contexto del marco de la capa. Vea la sección anterior de este capítulo sobre Ventanas de Mapas y Marcos de Capas para obtener información acerca de la amplificación de estos elementos.

## Enlace Grupal (Group Link)

Cuando una capa es parte de una colección, es posible aumentar y hacer un paneo a todos los miembros del grupo simultáneamente de la misma manera. Para activar esto, haga click en el botón Goup Link de la barra de herramientas. Observe que el botón se oprime y permanece oprimido hasta que se vuelve a hacer clic sobre el mismo. Esta característica es especialmente útil cuando se corrige una imagen de sensor remotos, particularmente cuando se utiliza con el link GPS (ver abajo).

El Enlace Grupal sólo funciona cuando las capas se abren con su referencia de colección completa. Las capas que pertenecen a archivos grupales raster pueden existir aisladamente o referenciadas como parte de un grupo. Por lo tanto, si desea utilizar una característica de enlace grupal, asegúrese de ingresar la referencia de colección completa (Ej.: "spotxs.band3" y no solamente "band3").

## Marcas de Lugar (Placemarks)

Las marcas de lugar son los equivalentes espaciales de los bookmarks. Cualquier vista particular de una composición puede ser guardada como marca de lugar. Para hacer esto, abra el diálogo Map Properties (Propiedades del Mapa) y haga clic sobre la ficha Placemarks o bien cliquee el icono Placemarks en la barra de herramientas. Luego elija la opción apropiada para nombrar (name), renombrar (rename), borrar (delete) o para ir (go) a cualquier

marca de lugar. Observe que las marcas de lugar son almacenadas con las composiciones de mapas. Éstas no se almacenarán si no se guarda la composición.

## Medir Longitud (Measure Length)

Las distancias se pueden medir en las composiciones de mapas. Con una imagen visualizada, haga clic en el ícono Measure Length (Medir Longitud). Para comenzar a medir la distancia, mueva el mouse al lugar de partida deseado y haga clic con el botón izquierdo del mouse. Aparecerá un globo encima del cursor que indicará la longitud mientras usted mueve el mouse. Si la longitud no es lineal, haga clic con el botón izquierdo del mouse para marcar los puntos de inflexión mientras usted toma las medidas. Finalice la medición haciendo clic en el botón derecho del mouse.

## Medir Zona (Measure Zone)

Las zonas circulares se pueden medir en las composiciones de mapas. Con una imagen visualizada, haga clic en el ícono Measure Zone (Medir Zona). Para comenzar a medir las zonas circulares, mueva el mouse al lugar de partida deseado y haga clic con el botón izquierdo del mouse. Aparecerá un globo encima del cursor que indicará la longitud desde el centro de la zona. Se dibujará una zona circular mientras usted mueve el mouse. Finalice la medición haciendo clic en el botón derecho del mouse.

## Asistencia del GPS

IDRISI también brinda asistencia GPS en tiempo real diseñada para ser usada con computadoras portátiles. Un receptor GPS (Global Positioning System-Sistema de Posicionamiento Global) recibe actualizaciones continuas de posicionamiento en latitud/longitud<sup>36</sup> de los satélites de navegación GPS activos. Cuando el link GPS de IDRISI está activo, esta posición se muestra gráficamente con un cursor intermitente sobre todas las ventanas de mapas que cubren su ubicación actual y tienen un sistema de referencia en común. IDRISI proyecta las posiciones entrantes automáticamente en el sistema de referencia especificado (siempre y cuando la proyección especificada esté aceptada por el PROJECT).<sup>37</sup> Además de guardar su ruta automáticamente, IDRISI le permite guardar los puntos de parada— notas adjuntadas posicionalmente.

La mayoría de las unidades de recepción disponibles en la actualidad asisten la comunicación con una computadora sobre un canal de comunicaciones RS232C. (Ej.: los puertos COM1 o COM2 de su computadora), y brindan apoyo para los protocolos de comunicación NMEA (National Marine Electronic Association). En la mayoría de los casos, el uso de un GPS de estas características con IDRI. SI es notablemente simple, y sólo requiere los siguientes pasos: Configure el GPS para enviar datos NMEA (usualmente esta opción se encuentra en su menú de instalación y puede permanecer como configuración predeterminada para evitar este paso en usos futuros).

Conecte el cable de comunicación especial diseñado para su GPS a uno de los puertos de comunicación en serie de su computadora. Para una notebook, éste es por lo general un puerto de 9 pins conocido como COM1. Por defecto, IDRISI se prepara para una comunicación sobre un puerto COM1, aunque esto puede cambiarse (ver abajo).

Despliegue una imagen o capa de mapa que incluya su ubicación actual. Asegúrese de que esté activa y luego haga clic en el botón GPS de la barra de herramientas. Luego verá que el cursor de posición intermitente aparece simultáneamente en todas las ventanas de mapas que utilizan el mismo sistema de referencia (siempre que su posición real esté dentro del área que se muestra).

Cuando termine una sesión GPS, cliquee nuevamente el botón GPS para desactivarlo. En ese momento, le dará la opción de guardar su ruta como una capa vectorial de líneas y sus paradas (si existen) como una capa vectorial de puntos.

## Cómo Guardar Rutas y Puntos de Parada

Mientras el GPS está conectado y en comunicación con IDRISI, automáticamente guarda la ruta que se inició en el momento en que se presionó por primera vez el botón GPS. Además guarda un registro de todas las paradas ingresadas durante el camino. Cuando se hace clic en el botón GPS nuevamente para finalizar la comunicación con el GPS, tiene la opción de guardar las rutas y paradas como capas. La ruta es almacenada como una capa vectorial de líneas y el archivo de paradas se almacena como una capa de texto.

<sup>36</sup> En realidad, el sistema de referencia original es un dato tridimensional conocido como WGS84. No obstante, la interfase NMEA para la comunicación de arreglos convierte éstos en lecturas de latitud/longitud y de elevación.

<sup>37</sup> Vea el capítulo Georeferenciamiento de este manual para abordar el tema de las proyecciones y los sistemas de referencia.

Para guardar las paradas, simplemente presione la tecla “w” en las posiciones donde desea guardar información.

Luego aparece un diálogo que le permite ingresar una descripción en texto. IDRISI mantiene un registro de la ubicación y del descriptor de texto. Advierta que como es una capa de texto, su información de paradas se visualiza con facilidad después de que el archivo ha sido almacenado. Sin embargo, es probable que Ud. desee que estos descriptores de paradas sean breves. Las lecturas de posición continúan grabándose mientras se ingresa la información de paradas.

Finalmente, observe que IDRISI no está diseñado como una herramienta de desarrollo de bases de datos espaciales. Entonces, las funciones de almacenamiento de rutas y paradas están mejor equipadas para realizar simples operaciones de verdad de terreno que para desarrollar bases de datos. Para capacidades mucho más extensas, recomendamos CartaLinx, el cual provee facilidades completas para el desarrollo de bases de datos con la asistencia de GPS.

## Cómo Funciona

Cuando hace clic en el botón GPS, IDRISI verifica si hay una capa de mapa activa y con un sistema de referencia válido. Éste puede ser cualquier sistema con un archivo de Parámetro del Sistema de Referencia que tenga una proyección aceptada por PROJECT (esto no incluye el sistema llamado “plane”). Éste luego se convierte en el sistema de referencia de salida, y todas las posiciones se convertirán a ese formato automáticamente.

Luego, IDRISI inicia (si no se encuentra activo ya) un programa especial para GPS llamado IDRNMEA.EXE de la carpeta llamada GPS ubicada en la carpeta de programas de Idrisi Selva.<sup>38</sup> Enseguida se establece comunicación con el GPS usando los parámetros de comunicación almacenados en un archivo especial llamado “IDRNMEA.CFG”, también ubicado en la carpeta GPS de la carpeta de programas de Idrisi Selva. Las configuraciones por defecto almacenadas en este archivo (1,4800,n,8,1) son probablemente correctas para su unidad (ya que éstas asumen el uso del puerto serial 1 y cumplen con los requisitos del estándar NMEA) y pueden, en la mayoría de los casos, ser usadas sin modificación alguna. No obstante, si tiene problemas para comunicarse con el GPS, este archivo puede ser editado usando un editor de texto ASCII como el módulo Edit de IDRISI o el Bloc de Notas de Windows. Para más detalles, diríjase al Sistema de Ayuda on-line.

Una vez que la comunicación ha sido establecida, IDRISI convierte el formato original de latitud/longitud del GPS NMEA en el sistema de referencia de IDRISI que haya sido designado. Luego, verifica todas las ventanas de mapas para averiguar cuáles están usando este sistema; y por último mueve un cursor intermitente a esa ubicación en cada una de las ventanas.

## Digitalización Interactiva de la Pantalla

Otra capacidad interactiva muy importante que ofrece IDRISI es la habilidad para digitalizar sobre la pantalla. Es importante reconocer, sin embargo, que esta utilidad está en gran medida diseñada como un medio para cumplimentar tareas simples de digitalización como la delineación de sitios de práctica para la clasificación de imágenes captadas con sensores remotos, o la creación de capas vectoriales de texto con mucha celeridad. Para tareas más grandes y complejas, recomendamos CartaLinx, un software completo para construir bases de datos espaciales, también disponible en Clark Labs.

El botón Digitize (Digitalizar) de la barra de herramientas tiene forma de una cruz dentro de un círculo y puede encontrarse entre un grupo de tres botones de digitalización relacionados.

Icono de la Barra de Herramientas	Acción
	Digitize (Digitalizar)
	Delete Feature (Borrar Característica)
	Save Digitized Data (Guardar Datos Digitalizados)

<sup>38</sup> Este es el mismo sistema usado por CartaLinx. El programa servidor de GPS puede servir múltiples aplicaciones simultáneamente. Entonces, si ya está cargado para ser usado por CartaLinx, IDRISI no carga otra copia, sino que simplemente se registra como otro usuario.



Para digitalizar sobre la pantalla, asegúrese de que esté activa la ventana de mapa apropiada, y luego cliquee el botón Digitize. Si la capa activa (la que está resaltada en el Diseñador) es una capa raster, se le presentará un cuadro de diálogo en el que puede definir la nueva capa vectorial que va a ser creada. Si la capa activa es una capa vectorial, primero se le preguntará si desea crear una nueva capa vectorial para las características digitalizadas o adjuntar las nuevas características a aquellas que ya existen en la capa activa. Si elige la opción de adjuntar, notará que la información del archivo ya está completada y solo necesita ingresar el ID o valor. Si está digitalizando un nuevo archivo, se le pedirá que especifique lo siguiente:

## Tipo de Datos

El tipo de datos se refiere al atributo almacenado para cada característica. Éste puede ser entero o real. Si está digitalizando identificadores que van a ser asociados con datos de una tabla, éste debe ser entero<sup>39</sup> En todos los demás casos, use atributos enteros para codificar datos cualitativos y reales para grabar datos cuantitativos (donde puede necesitarse un número fraccional) o cuando se sabe que el valor excede el rango entero.<sup>40</sup>

## Tipo de Capa

Especifique la naturaleza de las características que desea crear. Advierta que si desea adjuntarlas a una capa existente, tanto el tipo de capa como el tipo de datos están predeterminados para coincidir con aquellos de la capa existente y Ud. no podrá cambiar esa configuración. Las opciones del tipo de capa incluyen puntos, líneas, polígonos y texto.<sup>41</sup>

## Índice Automático (Automatic Index)

Esta opción es para aquellos casos en los que se almacenan identificadores para las características o detalles (en lugar de almacenar algún atributo directamente). Una vez verificada, la opción aumentará automáticamente el identificador de una característica a la otra. Esto brinda velocidad cuando se están digitalizando las características cuyos IDs (identificadores) incrementan en esta forma simple.

## ID o Valor / Índice de la Primera Característica

Esto le permite especificar el ID o atributo de la característica que va a digitalizar. Cuando la función Automatic Index (Indexación Automática) está especificada, este elemento será usado como el valor inicial para la secuencia numérica.

Una vez que haga clic en OK en este diálogo de inicio, se agregará una nueva capa a su composición (a menos que Ud. elija adjuntar a una capa existente), y el cursor digitalizador aparecerá en el Marco de la Capa. Advierta que si el cursor estuviese en modo Consultas (Inquiry) o de Propiedades de las Características, estos modos estarán desactivados temporalmente hasta que salga del modo de digitalización.

## Funciones de los Botones del Mouse cuando se Digitaliza

Una vez que se ha completado el cuadro de diálogo Digitize y Ud. ha hecho clic en OK, puede comenzar a digitalizar. Para digitalizar, use el botón izquierdo del mouse para identificar los puntos que definen la posición, curso o límites de una característica. Podrá ver que esto va ocurriendo mientras Ud. está digitalizando. Para concluir la característica (o la secuencia actual de puntos en el caso de características de puntos), haga clic en el botón derecho del mouse.

## Cómo Borrar Características

El botón Delete Feature (borrar característica) ubicado a la derecha del botón Digitize en la barra de herramientas permite seleccionar y borrar características vectoriales de la capa vectorial activa. Primero cliquee el icono Delete Feature, luego seleccione la característica que va a ser borrada (el cursor se convertirá en una mano). Cuando la característica está seleccionada, se vuelve roja. Para borrarla del archivo, presione la tecla Suprimir (Supr. o Del.) del teclado.

<sup>39</sup> Con datos vectoriales, no se hace distinción entre los diferentes formatos de almacenamiento de los enteros. Los datos vectoriales enteros pueden tener valores entre  $\pm 2.147.483.647$ .

<sup>40</sup> Aunque las capas vectoriales pueden llevar valores de atributos enteros dentro de un rango de  $\pm 2.147.483.647$ , las capas raster enteras están limitadas a un rango de  $\pm 32.767$ . Entonces, si pretende rasterizar sus datos digitalizados más adelante, es mejor que se los especifique como reales si el rango se encuentra fuera de  $\pm 32.767$ .

<sup>41</sup> Cuando se eligen polígonos, se presenta una opción para digitalizar un polígono de inundación. Esto es útil en la clasificación de imágenes para delinear sitios de práctica o entrenamiento. Vea el capítulo Clasificación de Imágenes de Sensores Remotos para más información.

## **Cómo Digitalizar Características Adicionales Dentro de un Solo Archivo**

Una vez que ha terminado una característica haciendo clic en el botón derecho del mouse, puede continuar agregando más características en el mismo archivo de datos de capa vectorial. Asegúrese de que la ventana del mapa aún está activa, y de que la capa a la cual desea adjuntar otra característica está resaltada. Luego haga clic en el botón Digitize de la barra de herramientas. Se le preguntará si desea adjuntar la nueva característica en la capa designada.

## **Cómo Guardar la Capa Vectorial**

Mientras se van digitalizando las características, éstas se agregan una por una en la capa vectorial designada. Sin embargo, estos datos no son asignados al disco hasta que Ud. haga clic en el botón Save Digitized Data (guardar los datos digitalizados). Esto se puede realizar repetidamente a través de una sesión para guardar su trabajo en forma creciente. Si una ventana de mapa se cierra antes de que una capa digitalizada sea guardada, un mensaje le preguntará si desea o no guardar la capa o los cambios realizados en la misma.

## **Cómo Digitalizar Capas Múltiples**

Ud. puede tener múltiples capas vectoriales abiertas para ser digitalizadas al mismo tiempo. Cualquier acción que realice sólo se aplicará a la capa activa, cuyo nombre está resaltado en el Diseñador.

## **Nota Especial acerca de la Digitalización de Características de Puntos**

Con capas tanto poligonales como lineales, se digitaliza una sola característica por vez, haciendo un clic derecho del mouse y luego otro clic en el botón Digitize para digitalizar la próxima característica. No obstante, con capas vectoriales de puntos, se pueden digitalizar características múltiples antes de terminar una secuencia haciendo clic con el botón derecho del mouse. Para hacer esto, seleccione la opción Automatic Indexing.

## **Nota Especial acerca de la Digitalización de Características Poligonales**

Los polígonos están definidos por líneas que se unen entre ellas mismas. Cuando se digitalizan características poligonales, un clic en el botón derecho no solo termina la definición de la característica, sino que también agrega un punto final idéntico al primero, de esta manera cierra perfectamente la característica. Como resultado, no es necesario tratar de cerrar la característica a mano – esto se hará de forma automática.

## **Nota Especial acerca de las Capas Fotográficas**

IDRISI tiene la habilidad de mostrar capas fotográficas encima de capas de mapas. Las Capas Fotográficas (Photo Layers) combinan fotos a través de los archivos vectoriales de texto de IDRISI con una sintaxis especial. Esta opción es muy útil para combinar fotos del campo durante un ejercicio de verdad de terreno. Las fotos deben estar en formato JPG. Las Capas Fotográficas son creadas como capas de texto durante el proceso de digitalización en pantalla, digitalizando una nueva capa de texto o bien estableciendo los puntos de partida durante la interacción con GPS. En ambos casos, al ingresar la sintaxis correcta para el título del texto se creará una Capa Fotográfica. Ir a Ayuda para más detalles.

## **Nota Final**

Tal vez la mejor manera de aprender más acerca del sistema de visualización de IDRISI es trabajar con los primeros ejercicios de guía del Tutorial. Éstos brindan instrucciones paso a paso y lo guían a través de los conceptos básicos de la visualización de capas y de la composición de mapas en IDRISI.

# CAPÍTULO 7 - Módulos de IDRISI

La finalidad de este capítulo es dar un breve panorama general de la funcionalidad de cada uno de los módulos de IDRISI. Los módulos son presentados con la misma lógica de la estructura del menú IDRISI. Los usuarios deben utilizar este capítulo para ver la amplitud del sistema de IDRISI. Y sin dudas, el usuario va a querer seguir en detalle todos los módulos en el sistema de Ayuda on-line de IDRISI. Allí encontrará una discusión en profundidad del funcionamiento de los módulos, sus algoritmos, consideraciones especiales, parámetros de líneas de comando y, cuando sea posible, referencias completas acerca de dónde se pueden encontrar aún más detalles.

El Menú Principal (Main Menu) de IDRISI está dividido en nueve partes, cada una de las cuales se describe más adelante. Las entradas del menú que tienen una flecha, conducen a submenús con más opciones. Debido a que algunos módulos se utilizan en contextos diferentes, pueden aparecer en más de un lugar dentro del menú.

Los nombres de los módulos del IDRISI que pueden usarse en modo macro se muestran en el menú escritos por completo con letra mayúscula. Todos los demás módulos e interfaces se muestran sólo con la primera letra en mayúscula.

## Menú Archivo (File Menu)

El menú Archivo incluye todos los módulos con fines generales de IDRISI.

**IDRISI Explorer** (Explorador de IDRISI) es una herramienta con fines generales para administrar y explorar archivos y proyectos de IDRISI. Use el Explorador de IDRISI para establecer el ambiente de su proyecto, administrar sus archivos grupales, repasar los meta datos, visualizar archivos y simplemente organizar sus datos con herramientas tales como copy (copiar), delete (borrar), rename (cambiar nombre) y move commands (mover los comandos).

**Collection Editor** (Editor de Colecciones) es usado para la creación de archivos grupales.

**Run Macro** (Ejecutar Macro) le permite iniciar un módulo de IDRISI en modo macro. Los comandos Macro permiten el procesamiento por lotes de los módulos de IDRISI. Active y desactive alternativamente el comando Shortcut (Atajo) en el menú Archivo para abrir una lista en orden alfabético de los módulos de comando de IDRISI.

**User Preferences** (Preferencias del Usuario) le permite personalizar su ambiente de trabajo de IDRISI y mostrar las preferencias.

Las entradas **Import** (Importar) y **Export** (Exportar) del menú Archivo activan submenús. Estos submenús están organizados en cuatro grupos. **General Conversion Tools** (Herramientas Generales de Conversión) son módulos que pueden usarse solos o en combinación para cambiar archivos a un formato IDRISI. El grupo **Government/Data Provider Formats** (Formatos Proveedores de Datos del Gobierno) (sólo de importación) incluye módulos que importan los formatos de datos del gobierno y agencias más comúnmente utilizados. Del mismo modo, el grupo **Desktop Publishing Formats** (Formatos Gráficos) incluye módulos que importan los formatos de datos de intercambio gráfico usualmente usados en software gráficos. Finalmente, el grupo **Software-Specific Formats** (Formatos de Software Específico) ofrece los módulos usados para importar archivos desde muchos SIG y paquetes de software relacionados.

**General Conversion Tools** (Herramientas de Conversión General) incluyen:

**GENERICRASTER** es una herramienta con fines múltiples para importar datos raster en una variedad de tipos y formatos de datos, incluyendo byte, íntegros y reales, banda intercalada por línea (BIL), banda intercalada por píxeles (BIP) y formatos de bandas secuenciales (BSQ);

**CRLF** agrega o elimina barras espaciadoras o alimentación de líneas;

**XYZIDRIS** se usa para importar datos de coordenadas ASCII X, Y, Z a un archivo vectorial de puntos como los recogidos por una unidad GPS o los ingresados a mano en una hoja de cálculo o archivo de texto;

**VAR2FIX** cambia los archivos ASCII de longitud variable a archivos de longitud fija, y

**SSTIDRIS** se utiliza para importar datos de hojas de cálculo cuando las celdas de la hoja de cálculo se deben interpretar como celdas en la imagen resultante.

**Government/Data Provider Formats** (Formatos Proveedores de Datos del Gobierno) incluyen herramientas sólo de exportación para:

**Landsat ETM** para formatos NLAPS, FAST, GEOTIFF o HDF;

**SPOT** para datos satelitales SPOT en formato GEOTIFF, SPOT Scene (CAP) o GEOSPOT – SPOTView;

**GEOTIFF** para archivos GEOTIFF/TIFF genéricos;

**HDFEOS** para formatos HDF-EOS4 incluyendo HDF 4 y HDF-EOS 4;

**MODISCONV** importa las imágenes MODIS en mosaico;

**MODISQC** crea los grupos de datos científicos de control de calidad para los productos de datos MODIS;

**GACPIDRIS** importa datos de Global Aerosol Climatology Project a IDRIS;

**NETCDF** importa datos de NETCDF a IDRIS;

**OLRIDRIS** importa Radiación Saliente de Onda Larga a IDRIS;

**PSIDRIS** importa la División de Ciencias Físicas en formato estandar en IDRIS;

**XYZMONTHLY** convierte los datos mensuales x, y y multi-z de la Universidad del Centro de Delaware por Investigaciones Climáticas ASCII a IDRIS;

**ASDIDRIS** importa los datos del espectrómetro recogidos con el Dispositivo de Análisis Espectral (ASD);

**SACIDRIS** para datos del satélite SAC-C de Argentina;

**RADARSAT** para datos Internacionales de RADARSAT;

**GOODE2LL** para datos compuestos de 10 días de Global AVHRR tomados por USGS NASA DAAC en la proyección Goodes Homosoline;

**STDS** para Datos Raster Espaciales de Transferencia Estándar;

**DLG** para datos de Gráficos Digitales de Líneas (Formato Opcional);

**CTG** para los datos de la Grilla de Temas del Compuesto; y

**DEMIDRIS** para Modelos de Elevación Digital USGS.

**Desktop Publishing Tools** (herramientas del escritorio) incluyen capacidades de importación y exportación para:

**BMPIDIRS** para archivos Bitmap de Windows (BMP);

**DXFIDRIS** para archivos CAD DXF;

**GEOTIFF/TIFF** para archivos con Formato de Información Tagged (TIFF); y

**JPGIDRIS** para archivos JPEG.

**KMLIDRIS** permite convertir entre formatos vectoriales y raster de KML e IDRIS

Observe que existe la capacidad para guardar un mapa actualmente en pantalla en formato Windows Metafile (WMF) o Windows Metafile Mejorado (EMF) a través del cuadro de diálogo Save Composition (Guardar Composición) dentro de Display System Composer (Diseñador del Sistema de Visualización).

**Software-Specific Formats** (Formatos para Software Específicos) incluye herramientas para importar y exportar:

**SHAPEIDR, ARCASTER y ARCIDRIS** para archivos ESRI Shape, ArcInfo Raster Exchange y formatos de archivo ArcInfo GENERATE/UNGEN, respectivamente;

**ATLIDRIS**; para archivos Atlas\*SIG BNA;

**ECWIDRIS** para archivos ECW;

**ENVIIDRIS** para archivos ENVI;

**ERDIDRIS** para archivos Erdas LAN y SIG;

**ERMIDRIS** para archivos ER Mapper;

**GRASSIDR** para archivos raster GRASS;

**MAPIDRIS** para archivos Map Analysis Package (Análisis de Mapas);

**MIFIDRIS** para archivos MapInfo Interchange (Intercambio de Información de Mapas);

**SRFIDRIS** para archivos Surfer GRD;

**SPLUSIDRIS** para archivos estadísticos SPLUS; y

**STATIDRIS** para archivos STATISTICA.

Los archivos de Palette (Paleta) pueden ser importados y exportados con el módulo **PALIDRIS**. Los archivos Vector Export Format (Formato de Exportación Vectorial) de IDRISI (.vxp) pueden ser importados/exportados con la función **Vector Export Format**.

La función **File Conversion (16/32)** (Conversión de Archivos) de IDRISI convierte las anteriores versiones de 16 bits de los archivos de IDRISI a la actual versión de 32 bits.

## Menú de Visualización (Display Menu)

El menú Display brinda todas las herramientas para visualizar archivos vectoriales o raster o bien para mejorar sus características de visualización.

**Display Launcher** (Iniciador de Visualización) es el punto de entrada en el sistema de visualización extensiva y composición de mapas de IDRISI. Permite volver a visualizar una composición existente o iniciar una nueva composición desplegando una imagen raster o una capa vectorial.

**PYRAMID** crea la estructura de almacenamiento piramidal raster para su visualización.

**ORTHO** es una utilidad para crear visualizaciones con perspectiva ortográfica (3-D) de modelos de elevación digital (DEMs) o cualquier imagen raster continua.

**VFIELD** crea parcelas de campos vectoriales.

**Fly Through** (Vuelo) es un reproductor visual 3-D interactivo con tecnología OpenGL que permite simular movimiento a través del espacio usando imágenes existentes de IDRISI.

**Media Viewer** (Reproductor Multimedia) es una función de representación que puede ejecutar archivos de video de Windows (AVI) y puede crear archivos de video AVI a partir de una secuencia de imágenes de IDRISI.

**Symbol Workshop** (Taller para Símbolos) permite crear y modificar archivos de símbolos y paleta para imágenes vectoriales y raster.

**COMPOSITE** (Compuesto) produce una imagen compuesta a color de 24 bits a partir de tres bandas de imágenes.

**SEPARATE** (Separar) realiza la separación de colores de las imágenes de paleta en componentes RGB.

**ILLUMINATE** (Iluminar) es una función para la fusión de sombras.

**HISTO** (Histograma) ofrece un histograma de frecuencia y estadísticas de los valores de las celdas dentro de una imagen, presentadas en forma gráfica o numérica.

**STRETCH** (Estirar) aumenta el contraste en una imagen para mejorar la interpretación visual.

## Menú de Análisis SIG (GIS Analysis Menu)

En el mismo centro de SIG se encuentra la habilidad para realizar análisis basados en ubicaciones geográficas. En realidad, ningún otro tipo de software puede ofrecer esto. IDRISI brinda una gran cantidad de herramientas analíticas para el análisis geográfico.

GIS Analysis Menu (Menú de Análisis SIG) contiene ocho submenús. Los primeros cuatro están organizados por tipo de herramienta, siguiendo la lógica que presenta el capítulo Introduction to GIS (Introducción a SIG). El resto de los submenús están organizados según el tipo particular de análisis que se realizará. Estos grupos existen principalmente por conveniencia organizacional. La mayoría de los análisis necesitan el uso de herramientas de varios submenús.

Además de las descripciones generales de los módulos individuales y de sus usos típicos, esta sección contiene más información acerca del funcionamiento y la aplicación de los módulos en problemas particulares.

## Submenú de Consultas sobre Bases de Datos (Database Query Submenu)

**Database Query** (Consulta sobre Bases de Datos) es la operación más importante de SIG. Después de las descripciones del módulo hay una sección llamada Performing Database Query with IDRISI (Cómo Realizar Consultas sobre Bases de Datos con IDRISI), la cual describe con más detalle este procedimiento.

**RECLASS** (Reclasificar) produce una nueva imagen de mapa al reclasificar los valores de una imagen de entrada.

**OVERLAY** (Superponer o Solapar) puede realizar nueve operaciones diferentes entre dos imágenes incluyendo add (sumar), subtract (sustraer), multiply (multiplicar), divide (dividir), normalized ratio (proporción normalizada), exponentiate (exponenciar), minimize (minimizar), maximize (maximizar) y cover (cubrir).

**CROSSTAB** (Comparación Cruzada) realiza una comparación o correlación entre dos o tres mapas.

**Edit** (Editar) es la función del editor de texto de IDRISI para crear una variedad de archivos con formato ASCII relacionados con IDRISI.

**ASSIGN** (Asignar) asigna nuevos valores a una imagen.

**EXTRACT** (Extraer) calcula estadísticas de resumen para un grupo de mapas de entrada.

**BREAKOUT** crea mapas booleanos para todas las categorías en una imagen.

**HISTO** (Histograma) muestra un histograma de frecuencia gráfico o numérico y las estadísticas de los valores de celda dentro de una imagen.

**AREA** calcula el área en una variedad de unidades de cada clase en una imagen.

**PERIM** (Perímetro) calcula el perímetro de cada clase en una imagen.

**PROFILE** (Perfil) crea perfiles sobre el espacio consultando los valores a lo largo de una transepta lineal de una imagen, o sobre el tiempo consultando el valor de la misma ubicación en varias imágenes.

**QUERY** (Consultar) extrae píxeles designados por una máscara independiente dentro de un archivo secuencial para los análisis estadísticos subsiguientes.

**PCLASS** realiza una reclasificación de probabilidades cuando se conoce el nivel de incertidumbre en una imagen.

**Database Workshop** (Taller para Bases de Datos) es un administrador relacional de bases de datos y se encuentra en el corazón de la ayuda de IDRISI para las colecciones de capas que conectan archivos de definición de características vectoriales con tablas de bases de datos. Database Workshop brinda la capacidad para crear, editar y analizar archivos de bases de datos en IDRISI. IDRISI utiliza Microsoft ADO y Access Jet Engines como la base para Database Workshop. Con esta función, uno puede realizar una gran variedad de operaciones de bases de datos, incluyendo consultas, cálculos y visualización de mapas. Tanto la función Calculate (Calcular) como Filter (Filtrar) son complementadas con el uso de Structured Query Language (SQL) (Lenguaje Estructurado de Consultas). Para obtener más información, ver el capítulo sobre **Database Workshop** (Taller para Bases de Datos) en este volumen.

**Image Calculator** (Calculador de Imágenes) es una herramienta interactiva de modelamiento matemático que permite ingresar un modelo como una ecuación algebraica completa usando una interfase de tipo calculadora y es compatible con expresiones matemáticas y consultas lógicas.

## Submenú de los Operadores Matemáticos (Mathematical Operators Submenu)

IDRISI, como la mayoría de los sistemas raster de análisis geográfico, brinda un juego de herramientas matemáticas necesarias para álgebra de mapas completos.

**OVERLAY** (Superponer o Solapar) puede realizar nueve operaciones diferentes entre dos imágenes incluyendo add (sumar), subtract (sustraer), multiply (multiplicar), divide (dividir), normalized ratio (cociente normalizado), exponentiate (exponenciar), minimize (minimizar), maximize (maximizar) y cover (cubrir).

**SCALAR** (Escala) lleva a cabo operaciones aritméticas entre una constante y una sola imagen.

**TRANSFORM** (Transformar) puede realizar 15 operaciones matemáticas diferentes sobre los atributos de una sola imagen incluyendo logaritmos y antilogaritmos naturales, una transformación lógica, recíproco, potencia al cuadrado y raíz cuadrada, valor absoluto y todas las operaciones trigonométricas.

**Image Calculator** (Calculador de Imágenes) es una herramienta interactiva de modelamiento matemático que permite ingresar un modelo como una ecuación algebraica completa usando una interfase de tipo calculadora y es compatible con expresiones matemáticas y consultas lógicas.

## Submenú de los Operadores de Distancia (Distance Operators Submenu)

El tercer submenú de herramientas analíticas consiste en aquello que llamamos operadores de distancia.

**DISTANCE** (Distancia) calcula la distancia Euclídea verdadera de cada celda hasta el grupo de celdas objetivo más cercano como se ha especificado en una imagen separada.

**SPDIST** (Distancia Esférica) es el equivalente del módulo DISTANCE, excepto que tiene capacidad para el caso especial de unidades de distancia esférica (grados, radianes).

**COST** (Costo) calcula una superficie de distancia/proximidad donde la distancia se mide como la distancia de menor costo requerida para un movimiento sobre una superficie de fricción.

**BUFFER** (Memoria Intermedia Auxiliar) crea memorias temporales alrededor de cualquier grupo de características especificadas en una imagen.

El próximo grupo de cuatro módulos se utiliza cuando las fricciones actúan con fuerzas diferentes dependiendo de la dirección del movimiento. Para una discusión detallada del tema, consulte el capítulo Anisotropic Cost Analysis (Análisis de Costos Anisotrópicos).

**VARCOST** calcula una superficie de costo anisotrópico para movimientos con energía motriz en términos de dirección y magnitud.

**DISPERSE** (Dispersar) modela el movimiento causado por *fuerzas* anisotrópicas en términos de dirección y magnitud pero que no tienen fuerza motriz por sí mismas, a diferencia de VARCOST.



**RESULTANT** (Resultante) calcula el vector de fuerza resultante (como un par de imágenes de magnitud y dirección) a partir de dos pares de imágenes vectoriales de fuerza de entrada.

**DECOMP** (Descomponer) descompone un vector de fuerza (como un par de imágenes de magnitud y dirección) en imágenes de componentes X e Y, o toma imágenes de componentes X e Y y produce un par de imágenes vectoriales de fuerza.

**PATHWAY** (Ruta) calcula la ruta de la distancia de menor costo entre uno o más puntos y el/los punto(s) más bajo(s) de una superficie de distancia de costo acumulado.

**ALLOCATE** (Asignar) realiza asignaciones espaciales basadas en una imagen de distancia o de distancia de costo.

**RELOCATE** (Reasignar) mueve las características de una imagen a un grupo objetivo de características de otra imagen basada en la distancia mínima.

**THIESSEN** produce polígonos Thiessen (Tesselación Voronoi) alrededor de un grupo de puntos irregularmente distribuidos.

## Submenú de los Operadores de Contexto (Context Operators Submenu)

El cuarto grupo de herramientas del menú Analysis (Análisis) contiene operadores de *contexto* (también llamados operadores locales o vecinos). Con los operadores de contexto, a cada celda de la imagen de salida se le asigna un valor basado en su valor de la imagen original y en los valores de sus celdas vecinas próximas.

**SURFACE** (Superficie) calcula la pendiente, el aspecto o un modelo analítico de sombras de celdas de superficie a partir de una imagen de entrada dada de la altura de los terrenos (un DEM) o cualquier variable cuantitativa o continua.

**FILTER** (Filtrar) aplica 3 por 3, 5 por 5, 7 por 7, o kernels (moldes) definidos por el usuario para calcular valores nuevos valiéndose de una operación matemática sobre el valor original de la celda y sus vecinas. Los filtros siguientes están disponibles: de promedio, Gaussiano, de mediana, de desviación estándar, de cuadro adaptable, de modo, de mejoramiento de bordes Laplaciano, de paso alto, detector de bordes Sobel y el definido por el usuario.

**PATTERN** (Patrón) computa varios índices de patrón numérico (riqueza relativa, diversidad, dominio, frecuencia, fragmentación, y otros) usando un molde de 3 por 3, 5 por 5 o 7 por 7.

**TEXTURE** (Textura) calcula medidas de variabilidad (dimensión fraccional, frecuencia de clases, análisis de bordes, y otras) usando un molde de 3 por 3, 5 por 5 o 7 por 7.

**GROUP** (Agrupar) identifica áreas únicas de polígonos contiguos en una imagen.

**VIEWSHED** (Vista) determina todas las celdas visibles desde una o más celdas de punto de vista situadas sobre una superficie y puede calcular la proporción de las celdas de punto de vista desde las cuales es visible una celda de vista.

**WATERSHED** (Cuenca) calcula todas las celdas que pertenecen a las cuencas de una o más celdas de destino.

**HINTERLAND** (Zona Interior) determina el área de oferta dominada por centros de puntos de demanda.

**PIXEL LOCATION** (Ubicación del Píxel) crea nuevas imágenes que representan las coordenadas X e Y de cada centro de celda.

## Submenú de Estadísticas (Statistics Submenu)

Las estadísticas son un campo que provee herramientas para describir grupos de números. En IDRISI, el submenú Statistics (Estadísticas) brinda una serie de herramientas para realizar tanto análisis estadístico tradicional como rutinas especializadas de estadísticas espaciales.

**HISTO** ofrece un histograma de frecuencia gráfico o numérico y las estadísticas de los valores de las celdas dentro de una imagen.

**EXTRACT** (Extraer) calcula estadísticas de resumen para un grupo de mapas de entrada.

**PATTERN** (Patrón) computa varios índices de patrón numérico (riqueza relativa, diversidad, dominio, frecuencia, fragmentación, y otros) usando un molde de 3 por 3, 5 por 5 o 7 por 7.

**COUNT** (Contar) calcula una imagen de probabilidad de frecuencia relativa derivada de un juego de imágenes booleanas de entrada.

**REGRESS** (Regresión) lleva a cabo un análisis de regresión lineal con estadísticas de resumen y gráficos sobre pares de imágenes.

**MULTIREG** lleva a cabo un análisis de regresión multivariada entre imágenes, una variable dependiente y dos o más variables independientes.

**LOGISTICREG** (Regresión Logística) realiza un análisis de regresión logística sobre imágenes, una variable dependiente y dos o más variables independientes.

**MULTILOGISTICREG** (Regresión Logística Múltiple) realiza una regresión logística multinominal sobre imágenes donde la variable dependiente es multicategórica.

**TREND** (Tendencia) calcula superficies de tendencias más aptas de hasta noveno orden entre los valores de los píxeles y sus posiciones dentro de la imagen.

**AUTOCORR** calcula el coeficiente de autocorrelación del primer intervalo (lag) de una imagen, usando el método estadístico “I” de Moran.

**DURBIN WATSON** detecta la correlación serial de primer orden en una serie de imágenes o residuales.

**QUADRAT** realiza un análisis cuadrático, el carácter del patrón de un grupo de puntos, en términos de su proporción de varianza/promedio o densidad.

**CENTER** (Centro) calcula el centro medio (“centro de gravedad”) y el radio estándar de un grupo de puntos.

**CRATIO** mide el cociente de compactación de polígonos definidos.

**CROSSTAB** (Comparación Cruzada) realiza una tabulación cruzada o una correlación cruzada entre dos mapas cualitativos.

**VALIDATE** (Validar) calcula medidas especializadas Kappa que discriminan los errores de cantidad de los errores de ubicación entre dos mapas cualitativos.

**ROC** calcula la Característica Operativa Relativa al otorgar una medida de la correspondencia entre una imagen cuantitativa modelada que muestra la probabilidad de que exista una clase particular y una imagen booleana de esa clase como ocurre en verdad.

**SAMPLE** (Muestra) crea esquemas de muestreo de puntos sistemáticos, aleatorios y aleatorio estratificados.

**RANDOM** (Aleatorio) crea una nueva imagen de dimensiones especificadas con valores aleatorios que obedecen una distribución rectilínea, normal o normal log, según la media y la desviación estándar definidas por el usuario.

**STANDARD** (Estándar) convierte los valores de una imagen en resultados estándares.

**SPLUSIDRIS** importa y exporta imágenes y datos entre IDRISI y S-Plus.

**STATIDRIS** importa y exporta imágenes y datos entre IDRISI y Statistica.

## Submenú de Apoyo en la Toma de Decisiones (Decision Support Submenu)

Una de las aplicaciones más importantes de SIG es el apoyo en la toma de decisiones. En realidad, muchos de los análisis realizados con módulos de otros menús del IDRISI están pensados para asistir la toma de decisiones. Los

módulos en este menú son únicos en el sentido que tratan específicamente problemas de decisiones multiobjetivo y multicriterio sobre la asignación de recursos, y también problemas con la evaluación e incorporación de la incertidumbre en el proceso de la toma de decisiones. Para abordar con más profundidad estos temas, ver los capítulos sobre **Decision Support** (Toma de Decisiones).

El **Decision Wizard** (Guía de Decisiones) es un asistente automatizado que lo conduce a través de los problemas de evaluación de criterios múltiples de objetivo simple o múltiple. El Wizard (Guía) facilita el uso de **WEIGHT**, **MCE**, **RANK** y **MOLA**.

**WEIGHT** (Peso) emplea el Proceso de Jerarquía Analítica para computar el grupo más apto por medio de una comparación en pares de los factores en una evaluación multicriterio.

**MCE** realiza una evaluación multicriterio por medio de un análisis Booleano, de una Combinación Lineal Ponderada (Weighted Linear Combination-WLC) o de un Promedio Ponderado Ordenado (Ordered Weighted Averaging-OWA) de las imágenes de factores.

**RANK** (Ordenar) ordena todas las celdas en una imagen raster.

**TOPRANK** crea una imagen Booleana a partir de las celdas con mayor clasificación en una imagen.

**MOLA** realiza un análisis multiobjetivo de asignación de terreno usando una heurística de decisión para resolver los conflictos.

**STANDARD** convierte una imagen en resultados estándares.

**FUZZY** (Difuso) evalúa los valores (posibilidades) de pertenencia al grupo difuso o borroso de las celdas de datos basándose en cualquiera de las tres funciones de pertenencia: sigmoide, en forma de j y lineal, o a través de una pertenencia definida por el usuario. Se aceptan las variantes de aumento y disminución monótonas, simétricas y asimétricas.

**COUNT** (Contar) calcula una imagen de probabilidad de frecuencia relativa derivada de un juego de imágenes booleanas de entrada.

**MDCHOICE** resuelve los conflictos entre objetivos que compiten entre sí por medio de un procedimiento de puntos ideales múltiples.

El resto de los módulos en este submenú son utilizados en la evaluación y manejo de los errores en análisis geográficos.

**PCLASS** evalúa la probabilidad con la que las celdas de datos exceden o son excedidas por un umbral especificado basándose en el error RMS para el mapa de entrada.

**BAYES** evalúa la probabilidad de que una entidad pertenezca a alguno de los diferentes grupos.

**Belief** (Creencia) emplea el procedimiento Dempster-Shafer del Peso de la Evidencia para evaluar el grado con el cual la evidencia ofrece apoyo concreto para una hipótesis (creencia) y el grado con el que esa evidencia no invalida la hipótesis (factibilidad).

**RANDOM** (Aleatorio) crea imágenes aleatorias según modelos rectilíneos, normales o normales log.

**SAMPLE** (Muestra) crea esquemas de muestreo de puntos sistemáticos, aleatorios y estratificados aleatorios.

**ERRMAT** produce un análisis de matriz de errores de los datos de mapas categóricos comparados con la información de verdad terreno y clasifica errores de omisión y comisión, errores marginales y totales, Índice de Concordancia Kappa (Kappa Index of Agreement) por categoría e intervalos de confianza seleccionados.

## Submenú de Cambios / Series de Tiempo (Change / Time Series Submenu)

El análisis de cambios y series de tiempo es un área de aplicación importante para SIG y para el Procesamiento de Imágenes. Existe una constante necesidad de identificar y medir el cambio, y también de predecir los efectos del

cambio en el medioambiente a escalas locales y globales. Para obtener más información sobre esta área de aplicación, ver el capítulo **Análisis de Cambios y Series de Tiempo (Change and Time Series Analysis)**.

El tipo más simple de análisis de cambios es una comparación entre imágenes pertenecientes a dos fechas.

**IMAGEDIFF** compara dos imágenes cuantitativas de la misma variable para fechas diferentes.

**IMAGERATIO** compara dos imágenes cuantitativas de la misma variable para fechas diferentes a través de una relación de proporción.

**CVA (Change Vector Analysis/Análisis de Cambio Vectorial)** compara grupos de imágenes de dos bandas para dos fechas y calcula la magnitud y la dirección del cambio.

**CALIBRATE** (Calibrar) ajusta las características numéricas generales de una imagen para coincidir con un estándar externo usando regresión de imágenes, compensación y ganancia definidas por el usuario, o la media y la desviación estándar definidas por el usuario.

**CROSSTAB** (Comparación Cruzada) realiza una comparación o correlación entre dos o tres mapas.

Para analizar los cambios de varias fechas, se pueden usar los siguientes cuatro módulos.

**PROFILE** (Perfil) crea perfiles sobre el espacio consultando los valores a lo largo de una transepta lineal de una imagen, o sobre el tiempo consultando el valor de la misma ubicación en varias imágenes.

**TSA** (Análisis de Series de Tiempo) realiza Análisis Estandarizados de los Componentes Principales para los datos de series de tiempo.

**TFA** realiza análisis Fourier temporales sobre series de tiempo de imágenes.

**CORRELATE** (Correlacionar) calcula el Coeficiente de Correlación de Pearson entre un grupo de valores de un archivo de valores de atributo y los valores a través de una serie de tiempo de imágenes para cada píxel de una imagen.

**Media Viewer** (Reproductor Multimedia) es una función de representación que puede ejecutar archivos de video de Windows (AVI) y puede crear archivos de video AVI a partir de una secuencia de imágenes de IDRISI.

Los siguientes seis módulos se usan para modelar cambios futuros.

**MARKOV** analiza dos imágenes cualitativas de cubierta terrestre de distintas fechas y produce una matriz de transición, una matriz de áreas de transición y un juego de imágenes de probabilidad condicional.

**STCHOICE** (Elección Estocástica) crea un mapa estocástico de cubierta terrestre al evaluar las probabilidades condicionales de que cada cubierta terrestre pueda existir en cada ubicación de píxel en contra de una distribución aleatoria rectilínea de probabilidades.

**DISAGGREGATE** (Quitar) redistribuye las probabilidades condicionales de un tipo de cubierta terrestre particular de acuerdo con un patrón designado.

**NORMALIZE** (Normalizar) ajusta linealmente los valores de un juego de imágenes cuantitativas para que los valores sumen 1,0 en cada píxel.

**LOGISTICREG** (Regresión Logística) realiza un análisis de regresión logística sobre imágenes, una variable dependiente y dos o más variables independientes.

**CELLATOM** realiza un grupo de operaciones autómatas celulares según un grupo de reglas para cambiar los estados.

**CA\_MARKOV** es un procedimiento combinado autómata celular y predicción de cambios Markov en la cubierta terrestre que suma un elemento de contigüidad espacial así como también el conocimiento sobre la distribución espacial probable de las transiciones al análisis de cambio Markov.

**GEOMOD** es un modelo de simulación de cambios del uso del suelo que predice las ubicaciones de las celdas de la grilla que cambian con el paso del tiempo. Esta simulación puede ocurrir hacia delante o hacia atrás en el tiempo.

**VALIDATE** (Validar) calcula medidas especializadas Kappa que discriminan los errores de cantidad de los errores de ubicación entre dos mapas cualitativos.

**ROC** calcula la Característica Operativa Relativa al otorgar una medida de la correspondencia entre una imagen cuantitativa modelada que muestra la probabilidad de que exista una clase particular y una imagen booleana de esa clase como ocurre en verdad.

## Submenú de Análisis de Superficies (Surface Analysis Submenu)

El submenú del Análisis de Superficies (Surface Analysis) contiene cuatro títulos, cada uno de los cuales conduce a más submenús. Las descripciones de los módulos de estos submenús a menudo se refieren a datos de elevación y a modelos de elevación digital como ejemplos. Sin embargo, los módulos disponibles en el submenú de Análisis de Superficies ofrecen un poderoso grupo de técnicas analíticas que pueden ser aplicadas en cualquier dato cuantitativo continuo.

### Submenú de Interpolación (Interpolation Submenu)

El primer submenú del Análisis de Superficies es Interpolation. Los temas relacionados con la interpolación de superficies y también las opciones disponibles en el IDRISI se discuten en detalle en el capítulo **Interpolación de Superficies (Surface Interpolation)**.

**INTERPOL** interpola una superficie de acuerdo a un promedio de la distancia ponderada o a un modelo potencial con un grupo dado de puntos de entrada.

**INTERCON** interpola una superficie desde un juego de líneas digitalizadas.

**TIN** (Interpolación TIN) se trata con más detalle en el **capítulo Redes Triangulares y Generación de Superficies (Triangulated Networks and Surface Generation)**. Los módulos usados para preparar datos para la generación TIN, para crear y optimizar TIN y para interpolar una superficie completa desde TIN se encuentran todos en este submenú.

**TIN** crea una red irregular triangular restringida o no restringida a partir de datos de isolíneas o datos de puntos.

**TINSURF** interpola una superficie raster completa a partir de un modelo TIN y del dato de atributos del punto original.

**GENERALIZATION** crea un archivo vectorial de puntos a partir de los vértices de un archivo de líneas de entrada o reduce datos vectoriales de puntos según una distancia de búsqueda radial definida por el usuario.

**LINTOPNT** extrae los vértices de un archivo vectorial de datos de líneas y los coloca en un archivo vectorial de datos de puntos.

**TINPREP** agrega o quita puntos a lo largo de una isolínea, dada una distancia de tolerancia especificada por el usuario.

El submenú **Kriging** conduce a tres interfaces del paquete de software para el modelamiento geoestadístico Gstat<sup>42</sup>. El capítulo **Geoestadística** (Geostatistics) da un panorama del campo de la geoestadística y de las funciones brindadas por estas interfaces.

En la interfase **Modelador de Dependencia Espacial** (Spatial Dependence Modeler), el usuario emplea un amplio rango de herramientas para aprender acerca de los patrones de dependencia espacial en el juego de datos de muestra. En la interfase **Ajuste del Modelamiento** (Modeling Fitting), el usuario define modelos matemáticos para describir las relaciones de covarianza entre los datos de muestra. En la interfase **Kriging y Simulación** (Kriging and

---

<sup>42</sup> IDRISI brinda una interfase gráfica de usuario para Gstat, un programa para el modelamiento, predicción y simulación geoestadística escrito por Edzer J. Pebesma (Facultad de Geografía Física, Universidad de Utrecht). Gstat está disponible de forma gratuita bajo la Licencia Pública General GNU en [www.gstat.org](http://www.gstat.org).

Simulation), pueden crearse superficies raster completas a partir de datos de muestra, y los modelos pueden desarrollarse a través de las otras interfaces.

**THIESSEN** produce polígonos Thiessen (Teselación Voronoi) alrededor de un grupo de puntos irregularmente distribuidos.

**TREND** (Tendencia) calcula superficies tendenciales más aptas, de hasta noveno orden entre los valores de los píxeles y sus posiciones dentro de la imagen.

### Submenú de Geoestadística (Geostatistics Submenu)

El Segundo submenú en el submenú Análisis de Superficies (Surface Analysis) es Geoestadística (Geostatistics). El campo de la geoestadística posee un amplio rango de aplicaciones para muchos tipos de datos y análisis. El capítulo **Geoestadística** brinda un panorama completo de geoestadísticas y de las funciones disponibles en IDRISI a través de las tres interfaces para Gstat (ver la nota al pie de página).

En la interfase **Modelador de Dependencia Espacial** (Spatial Dependence Modeler), el usuario emplea un amplio rango de herramientas para aprender acerca de los patrones de dependencia espacial en el juego de datos de muestra. En la interfase **Ajuste del Modelo** (Modeling Fitting), el usuario define modelos matemáticos para describir las relaciones de covarianza entre los datos de muestra. En la interfase **Kriging y Simulación** (Kriging and Simulation), pueden crearse superficies raster completas a partir de datos de muestra, y los modelos pueden desarrollarse a través de las otras interfaces.

### Submenú de Variables Topográficas (Topographic Variables Submenu)

El submenú de Variables Topográficas (Topographic Variables) es el tercer submenú del grupo Análisis de Superficies (Surface Analysis) y contiene módulos que funcionan sobre imágenes de superficies para calcular una variedad de medidas. Las entradas **SLOPE** (Pendiente), **ASPECT** (Aspecto) y **HILLSHADE** (Sombreado) abren la interfase del módulo SURFASE.

**SURFASE** (Superficie) calcula la pendiente, el aspecto o bien un modelo de sombreado analítico de las celdas de superficie de una imagen de entrada determinada de alturas de terreno (un DEM) o de cualquier variable cuantitativa y continua.

**CURVATURE** (Curvatura) calcula el índice de cambio máximo de una curva ajustada a través de un píxel en la dirección del aspecto y también en la dirección ortogonal al aspecto.

**FRACTAL** calcula la dimensión fractal de una superficie usando una vecindad de 3 por 3.

### Submenú de Extracción de Características (Feature Extraction Submenu)

**CONTOUR** (Contorno) crea isolíneas vectoriales en intervalos de contorno específico a partir de una superficie continua.

**TOPOSHAPE** clasifica una superficie en once características diferentes: pico (peak), cresta (ridge), montura (saddle), llanura (flat), barranco (ravine), depresión (pit), ladera convexa (convex hillside), ladera de montura (saddle hillside), ladera de pendiente (slope hillside), ladera cóncava (concave hillside) y ladera de inflexión (inflection hillside).

**PIT REMOVAL** (Eliminación de Depresiones) crea un DEM ajustado “sin depresiones” en el cual las celdas contenidas en las depresiones son levantadas hasta el valor de elevación más bajo sobre el borde de la depresión.

**RUNOFF** (Esguimiento) calcula la acumulación de unidades de lluvia por píxel como si una unidad de lluvia cayera sobre cada ubicación.

**FLOW** (Flujo) calcula la dirección del flujo desde cada píxel a su vecino “en declive” más próximo.

**RUSLE** (Revised Universal Soil Loss Equation/Ecuación Universal Revisada de Pérdida del Suelo) simula la pérdida del suelo provocada por el agua en campos y pasturas no canalizadas.

**WATERSHED** (Cuenca) calcula todas las celdas que pertenecen a las cuencas de una o más celdas de destino.

**SLOPELENGTH** (Longitud de la Pendiente) calcula la longitud de pendiente más larga en una región raster dada.

**SEGMENT** (Segmento) produce una imagen de homogeneidad.

**SEDIMENTATION** (Sedimentación) evalúa el movimiento neto del suelo (erosión o deposición) dentro de segmentos, campos o cuencas de ríos.

## Menú de Modelamiento (Modeling Menu)

Los elementos pertenecientes al menú de Modelamiento (Modeling) detonan el poder para realizar el análisis raster en IDRISI. La mayoría de estos módulos se pueden encontrar en otros sitios dentro de la estructura del menú pero son incorporados aquí para ayudar a estructurar este diverso pero poderoso grupo de herramientas. El menú de Modelamiento en IDRISI está compuesto por tres grupos principales de opciones. Las **Herramientas para el Despliegue de Modelos** (Modeling Deployment Tools) incluyen módulos para desplegar modelos conceptuales o teóricos o bien, modelos matemáticos o lógicos existentes. Las **Herramientas para el Desarrollo de Modelos Empíricos** (Empirical Model Development Tools) incluyen módulos para el desarrollo de modelos empíricos a partir de prototipos. Los **Modelos Ambientales/de Simulación** (Environmental/Simulation Models) son un grupo de modelos establecidos que han sido implementados en el sistema de IDRISI.

Dentro de las **Herramientas para el Despliegue de Modelos**, probablemente la más directa y más fácil de entender sea **Image Calculator** (Calculador de Imágenes), un calculador matemático y lógico que utiliza las capas de mapas como variables. Para los modelos más relacionados con algoritmos, **Macro Modeler** (Modelador Macro) brinda una interfase de modelamiento gráfico muy avanzada. El Modelador Macro expone todos los módulos SIG de IDRISI como objetos que pueden ser unidos, dinámicamente y con respuestas, con capas de mapas en una cadena algorítmica. Para las aplicaciones de modelamiento algorítmico más exigentes, o para el desarrollo de módulos solitarios como agregados de IDRISI, puede usarse un lenguaje de escritura tal como **Python** o un lenguaje de programación completo como C++, Delphi o Visual Basic. En estos casos, los usuarios pueden acceder a IDRISI a través de la interfase industrial estándar de modelamiento de objetos **COM**. Al usar COM, las aplicaciones de los clientes que pueden ser escritas, pueden controlar todos los aspectos de las operaciones de IDRISI. Para tareas de modelamiento más simples, IDRISI ofrece el lenguaje de escritura macro **Run Macro** (Ejecutar Macro).

También hay enlaces directos con las herramientas principales usadas en la evaluación multicriterio (**MCE**) (normalmente asociadas a nuestro menú Decision Support), debido a la frecuencia con la que éstas son aplicadas para crear modelos de opinión experta.

Las **Herramientas para el Desarrollo de Modelos Empíricos** (Empirical Model Development Tools) brindan procedimientos de modelamiento empírico para analizar ejemplos de casos conocidos y su relación entre un fenómeno de interés y un grupo de variables explicativas, comúnmente llamadas datos de capacitación.

Dependiendo de la naturaleza de los datos, los modelos pueden ser desarrollados con Datos de Presencia, Datos de Presencia/Ausencia o Datos de Abundancia/Frecuencia/Valor. Existen menús para cada tipo de modelamiento.

**Los Datos de Presencia** (Presence Data) son casos donde no conocemos dónde se encuentra el fenómeno, sólo cuando éste ocurre. Un ejemplo clásico es el modelamiento de las distribuciones de especies a partir de informes de avistajes de animales. Existen pocas técnicas para el manejo de datos de este tipo. Sin embargo, IDRISI brinda el clasificador blando Mahalanobis Typicalities (**MAHALCLASS**) (que requiere un previo análisis de firmas con el módulo **MAKESIG**) el cual trabaja excepcionalmente con este tipo de datos.

Las herramientas de los **Datos de Presencia/Ausencia** (Presence/Absence Data) son para casos donde tenemos tanto los datos de presencia como los de ausencia para nuestros ejemplares. Se puede aplicar un amplio rango de técnicas de modelamiento incluyendo la regresión logística (**LOGISTICREG**) y la regresión logística multinomial (**MULTI LOGISTICREG**), procedimientos de clasificación de imágenes multivariadas (**BAYCLASS**, **FISHER**) y técnicas de aprendizaje de máquinas como las redes neurales (**MLP**, **SOM**, **Fuzzy ARTMAP**) y los árboles de clasificación (**CTA**).

La disponibilidad de **Datos de Abundancia/Frecuencia/Valor** (Abundance/Frequency/Value Data) hace posible el uso de herramientas tales como la regresión simple (**REGRESS**) y la multivariada (**MULTIREG**).

El grupo de menús **Modelos Ambientales/de Simulación** (Environmental/Simulation Models) brinda enlaces con una serie de modelos establecidos o ambientes de modelamiento asociados con áreas de aplicaciones específicas. Éstos se distribuyen en dos grupos: aquellos relacionados con el modelamiento del cambio de terreno y aquellos relacionados con el escurrimiento de agua en la superficie y la erosión del suelo. Esta herramientas incluyen:

**LCM Land Change Modeler for Ecological Sustainability** (Modelador de Cambios en el Terreno para el Sustento Ecológico), es un software integrado para analizar los cambios en la cubierta de terreno, proyectar su curso en el futuro y evaluar sus implicaciones en el cambio del hábitat y la biodiversidad.



**GEOMOD** es un modelo de simulación de cambios en el uso del suelo que predice las ubicaciones de las celdas de la grilla que cambian con el paso del tiempo.

**MARKOV** analiza dos imágenes cualitativas de la cubierta del terreno de fechas diferentes y produce una matriz de transición, una matriz de áreas de transición y un juego de imágenes de probabilidad condicional.

**CA\_MARKOV** es un procedimiento combinado celular autómatas / Markov para la predicción de cambios en la cubierta terrestre que agrega un elemento de contigüidad espacial así como también conocimiento de la distribución espacial probable de las transiciones al análisis de cambio Markov.

**RUSLE** (Revised Universal Soil Loss Equation/Ecuación Revisada de la Pérdida Universal del Suelo) simula la pérdida del suelo provocada por el agua en campos y pasturas no canalizadas.

**RUNOFF** (Esguerrimiento) calcula la acumulación de unidades de lluvia por píxel como si una unidad de lluvia cayera sobre cada ubicación.

**SEDIMENTATION** (Sedimentación) evalúa el movimiento neto del suelo (erosión o deposición) dentro de segmentos, campos o cuencas de ríos.

## Menú de Procesamiento de Imágenes (Image Processing Menu)

Junto con los operadores geográficos analíticos que se encuentran en IDRISI, las capacidades del Procesamiento de Imágenes (Image Processing) completan un juego de herramientas para el procesamiento de datos espaciales. Las funciones del Procesamiento de Imágenes se clasifican en diez categorías: restoration (restauración), enhancement (mejoramiento), transformation (transformación), Fourier analysis (análisis Fourier), signature development (desarrollo de firmas), hard classifiers (clasificadores duros), soft classifiers (clasificadores blandos), hardeners (endurecedores), hyperspectral analysis (análisis hiperspectral) y accuracy assessment (evaluación de exactitud).

Para mayor información, consulte el **capítulo Introducción a los Sensores Remotos y al Procesamiento de Imágenes**. Además, varios capítulos brindan discusiones de tareas particulares del procesamiento de imágenes con detenimiento. El capítulo **Restauración de Imágenes** aborda temas sobre la corrección geométrica y radiométrica y sobre los módulos del IDRISI diseñados para estos fines. El capítulo **Clasificación de Imágenes de Sensores Remotos** ofrece información más detallada sobre el proceso de clasificación y un resumen de los operadores de clasificación del IDRISI. El capítulo **Análisis Fourier** entrega información puntual acerca del uso y función de FOURIER y de sus módulos acompañantes del submenú Fourier Analysis. Finalmente, el **Tutorial** incluye un juego extensivo de ejercicios que cubren muchos aspectos del procesamiento de imágenes.

## Submenú de Restauración (Restoration Submenu)

La Restauración de Imágenes (Image Restoration) es la manipulación de imágenes de sensores remotos con la finalidad de eliminar distorsiones de valores conocidas. La Restauración puede ser geométrica o radiométrica. Los primeros dos módulos realizan correcciones geométricas que se usan para reducir la distorsión en los bordes de la imagen y para registrar la imagen en un sistema de coordenadas. Los otros módulos realizan restauraciones radiométricas para eliminar o disminuir las distorsiones en los valores de los datos de las imágenes.

**RESAMPLE** (Remuestreo) lleva a cabo una transformación a nivel local para la restauración geométrica de las imágenes y se usa para georegistrar una imagen en un sistema de referencia o en otro archivo.

**LOCALAFFINE** se utiliza para rectificar imágenes que tienen insertada una grilla de puntos de control con ubicaciones precisas conocidas.

**MOSAIC** (Mosaico) automatiza el balance de colores cuando las imágenes adyacentes superpuestas están unidas formando una sola gran imagen.

**DESTRIPE** (Eliminar Rayas) elimina las rayas provocadas por la producción variable del detector en imágenes escaneadas.

**RADIANCE** (Radiancia) convierte los valores de datos Landsat crudos en radiancia calibrada al usar tablas de búsqueda de valores de ganancia y compensación.

**ATMOSC** realiza los cálculos necesarios para corregir imágenes de sensores remotos debido a los efectos atmosféricos usando un modelo de Extracción de Objetos Oscuros (Dark Object Subtraction), un modelo Chavez's Cos(t), el modelo de ecuación de transferencia radiactiva completa o un Modelo de Reflectancia Aparente (apparent Reflectance Model) (ARM).

**NDVICOMP** crea imágenes compuestas temporales de imágenes NDVI usando el valor máximo o una media cuadrática.

**SCREEN** (Controlar) usa la autocorrelación espacial para controlar una serie hiperespectral de imágenes para detectar la presencia de ruido atmosférico significativo.

La eliminación simple de neblina se puede lograr con el módulo SCALAR. La línea con opción de saturación en STRETCH puede usarse a menudo para producir el mismo resultado.

Cuando DESTRIPE no se puede aplicar o no funciona bien, el Análisis de Componentes Principales (Principal Components Analysis) (PCA) o el Análisis Fourier (Fourier Analysis) pueden ofrecer soluciones para la eliminación de rayas en imágenes satelitales. Ver el capítulo **Restauración de Imágenes** (Image Restoration) para más detalles.

## Submenú de Mejoramiento (Enhancement Submenu)

El mejoramiento de imágenes es la modificación de los valores de las imágenes para resaltar información dentro de la imagen. La mayoría de las veces estas imágenes mejoradas son utilizadas en análisis visuales solamente, mientras que las imágenes originales se usan en análisis automatizados. El sistema de visualización de IDRISI incluye algunas utilidades para el mejoramiento de la visualización en pantalla. Éstas comprenden la habilidad para establecer interactivamente los puntos finales usados para aplicar la paleta de colores en las imágenes. No obstante, no se crean nuevos archivos con las herramientas de Visualización (Display). Para crear nuevas imágenes mejoradas, se utilizan con frecuencia los siguientes tres módulos.

**STRETCH** (Estirar) aumenta el contraste en una imagen para mejorar la interpretación visual.

**COMPOSITE** (Compuesto) produce una imagen compuesta a color de 24 bits a partir de tres bandas de imágenes.

**FILTER** (Filtrar) aplica 3 por 3, 5 por 5, 7 por 7, o kernels definidos por el usuario para calcular valores nuevos valiéndose de una operación matemática sobre el valor original de la celda y sus vecinas. Los filtros siguientes están disponibles: de promedio, Gaussiano, de mediana, de desviación estándar, de cuadro adaptable, de modo, de mejoramiento de bordes Laplaciano, de paso alto, detector de bordes Sobel y el definido por el usuario.

**PANSHARPEN** realiza una unión pancromática usando técnicas de transformación de colores del espacio, transformación de componentes principales y transformación de regresión local.

## Submenú de Transformación (Transformation Submenu)

**PCA** brinda análisis de componentes principales estandarizados y no estandarizados.

**CANCOMP** realiza una transformación del análisis de componentes canónicos.

**CANCOR** realiza una transformación del análisis de correlación canónica.

**MNF** (Fracción de Mínimo Ruido) maximiza la relación señal-ruido para un conjunto de imágenes;

**TFA** (Análisis Temporal de Fourier) realiza análisis armónicos en imágenes temporales;

**COLSPACE** lleva a cabo transformaciones espaciales de colores de Matiz/Brillo/Saturación (HLS) a Rojo/Verde/Azul (RGB) y viceversa.

**TEXTURE** (Textura) calcula medidas de variabilidad (dimensión fraccional, frecuencia de clases, análisis de bordes, y otras) usando un molde de 3 por 3, 5 por 5 o 7 por 7.

**THERMAL** (Termal) convierte valores de datos crudos Landsat TM de Banda 6 en temperaturas de cuerpos negros.

**VEGINDEX** computa 19 índices de vegetación basados en la pendiente y en la distancia de imágenes de sensores remotos. Ver el Capítulo sobre **Índices de Vegetación**.

**TASSCAP** realiza la transformación Tasseled Cap.

## Submenú de Análisis Fourier (Fourier Analysis Submenu)

Los módulos del submenú Análisis Fourier aceptan la aplicación del Análisis Fourier, una transformación entre dominios espaciales y de frecuencia. El capítulo **Análisis Fourier** ofrece información detallada acerca del uso de FOURIER y de sus módulos acompañantes y acerca de la interpretación de los resultados.

**FOURIER** permite la transformación de imágenes desde el dominio espacial al dominio de frecuencia y viceversa.

**ZEROPAD** se utiliza para preparar imágenes usadas en FOURIER.

**FILTERFQ**, **FREQDIST** y **DRAWFILT** facilitan la creación de filtros para ser aplicados en imágenes de dominio de frecuencia para mejorar, suprimir o eliminar frecuencias particulares antes de realizar una Transformación Fourier en reversa. **FILTERFQ** ofrece 26 tipos de filtros, cada uno con varias opciones definidas por el usuario. **FREQDIST** crea una imagen de distancia de frecuencia que luego puede ser manipulada con **RECLASS** o **FUZZY**. **DRAWFILT** brinda una utilidad de visualización interactiva en la que el usuario puede rastrear con el cursor frecuencias particulares para enmascarar.

## Submenú de Desarrollo de Firmas (Signature Development Submenu)

El Desarrollo de Firmas está mayormente asociado con los primeros pasos de la clasificación supervisada y generalmente requiere dos pasos – la creación de sitios de entrenamiento y la creación de archivos de firmas a partir de los sitios de entrenamiento. Los sitios de entrenamiento son ejemplos de clases informativas, por ejemplo, bosques, ciudades o pasturas que pueden caracterizarse a través de todas las bandas de una imagen. Estas caracterizaciones son luego usadas para crear firmas o patrones de respuesta espectral para cada clase informativa. La delineación de los sitios de entrenamiento a menudo se logra a través de la digitalización sobre la pantalla en el Sistema de Visualización del IDRISI o a través de la importación de datos GPS recogidos en el campo. El segundo paso, desarrollo de firmas, se logra con el uso de los módulos de este submenú.

**MAKESIG** crea archivos de firmas estadísticas para cada clase informativa del sitio de entrenamiento.

**Endsig** se usa para crear firmas de miembros finales (es decir, puros) para usar con UNMIX.

**FUZZSIG** produce firmas de datos que se suponen son de carácter inherentemente difuso o ambiguo.

**PURIFY** (Purificar) lleva a cabo una purificación paramétrica (distancia Mahalanobis) o no paramétrica (grupo no supervisado) sobre datos de sitios de entrenamiento existentes.

**HYPERSIG** crea firmas estadísticas a partir de datos hiperespectrales, de sitios de entrenamiento o bien de archivos de curvas espectrales.

**HYPERAUTOSIG** desarrolla automáticamente firmas para datos de imágenes hiperespectrales basándose en la lógica de Separación Espectral Lineal (Linear Spectral Unmixing).

**SIGCOMP** muestra y compara gráficamente las firmas.

**SEPSIG** brinda medidas estadísticas del nivel de separación de las firmas sobre un juego de bandas dado.

**SCATTER** (Dispersar) crea un gráfico de dispersiones del espacio de bandas entre imágenes usadas en la creación de firmas.

## Submenú de los Clasificadores Rígidos (Hard Classifiers Submenu)

Hay dos enfoques básicos al proceso de clasificación: clasificación supervisada y no supervisada. IDRISI ofrece las herramientas para ambos procesos con clasificadores rígidos y blandos a disposición. Este submenú incluye los clasificadores duros disponibles para la clasificación supervisada y no supervisada.

**PIPED** es un clasificador en Paralelepípedo.

**MINDIST** es un clasificador de la Distancia Mínima a la Media (Minimum Distance to Means).

**MAXLIKE** es un clasificador de Probabilidad Máxima (Maximum Likelihood) con opciones para especificar probabilidades anteriores como valores o imágenes.

**FISHER** ofrece una clasificación de imágenes basada en análisis discriminante.

**KNN** es un clasificador del vecino k más cercano.

**CLUSTER** (Agrupar) realiza una clasificación no supervisada usando una variante de la técnica de pico del histograma para crear una nueva imagen de grupos similares.

**ISOClust** es un procedimiento analítico de repetición de grupos auto-organizados que utiliza un número predeterminado de grupos.

**KMEANS** clasifica de acuerdo a la técnica de agrupamiento de la media K.

**MAXSET** es un clasificador rígido que asigna la clase con el mayor grado de compromiso a cada píxel basándose en una jerarquía Dempster-Shafer completa para describir todas las clases y sus combinaciones jerárquicas.

**CHAINCLUSTER** realiza la clasificación no supervisada del método en cadena

**MLP** lleva a cabo la clasificación de imágenes de sensores remotos por medio de la técnica de percepción multicapa de redes neurales artificiales.

**SOM** lleva a cabo una clasificación supervisada o no supervisada de imágenes de sensores remotos por medio de la técnica de Mapas Auto-Organizados (Self-Organizing Map) de redes neurales artificiales.

**Fuzzy ARTMAP** lleva a cabo una clasificación supervisada o no supervisada de imágenes de sensores remotos por medio de la técnica Fuzzy ARTMAP de redes neurales artificiales.

**RBFNN** realiza la clasificación supervisada de la Red Neural con Función de Base Radial.

**CTA** lleva a cabo la clasificación de imágenes de sensores remotos por medio del Análisis de Clasificación en Árbol (Classification Tree Analysis) con opciones de recortes automáticos y manuales.

## Submenú de Clasificadores Blandos / Análisis de Mezclas (Soft Classifiers / Mixture Analysis Submenu)

A diferencia de los clasificadores rígidos, los clasificadores blandos posponen la elaboración de un juicio definitivo acerca de la pertenencia de clase de cualquier píxel y, en cambio, hacen grupos de declaraciones acerca del grado de pertenencia de cualquier píxel dado en cada una de todas las clases posibles. Más aún, con los clasificadores blandos, el resultado no es una sola imagen o clasificación sino un juego de imágenes (una por clase) que expresa el grado de pertenencia que cada píxel posee en una clase particular. Estos módulos son muy importantes para desarrollar firmas robustas y evaluar técnicas de clasificación, y además son usados para la clasificación de subpíxeles y el análisis de mezclas. Varios módulos están disponibles y cada uno emplea una métrica establecida de pertenencia diferente para expresar el grado de pertenencia de cualquier píxel a cualquier clase. Se proveen módulos para el uso con juegos de imágenes multiespectrales e hiperespectrales.

**BAYCLASS** emplea la teoría de probabilidad Bayesiana para expresar el grado de pertenencia de un píxel a cualquier clase.

**MAHALCLASS** calcula la distancia Mahalanobis para producir un nuevo juego de clases de firmas.

**BELCLASS** emplea la teoría Dempster-Shater para expresar el grado de pertenencia de un píxel a cualquier clase.

**FUZCLASS** emplea la teoría Fuzzy Set para expresar el grado de pertenencia de un píxel a cualquier clase.

**KNN** es un clasificador del vecino k más cercano que puede expresar el grado de pertenencia de un píxel a cualquier clase.

**MLP** lleva a cabo la clasificación de imágenes de sensores remotos por medio de la técnica de percepción multicapa de redes neurales artificiales con una opción para producir capas blandas de nivel de activación para cada clase..

**SOM** lleva a cabo una clasificación supervisada o no supervisada de imágenes de sensores remotos por medio de la técnica de Mapas Auto-Organizados (Self-Organizing Map) de redes neurales artificiales con una opción para producir capas blandas típicas o de compromiso para cada clase.

**UNMIX** se usa para clasificar imágenes de sensores remotos usando Separación Espectral Lineal (Linear Spectral Unmixing) (LSU – también llamada Modelamiento de Mezcla Lineal).

**HYPERUSP** provee clasificación no supervisada para datos de imágenes hiperespectrales.

**HYPEROSP** provee clasificación de imágenes hiperespectrales a través de un enfoque de proyección subespacial ortogonal.

**HYPERUNMIX** extiende las capacidades de Separación Espectral Lineal a juegos de datos hiperespectrales.

**HYPERABSORB** hace posible la clasificación hiperespectral de imágenes basándose en espectros de archivos y en la eliminación continua de áreas de absorción y la correlación de estas áreas en términos de adecuación y profundidad entre el espectro de archivos y los espectros de un juego de datos de imágenes.

**BELCALC** calcula el grado de pertenencia que cada píxel exhibe para cada una de las clases para las que se han suministrado datos de práctica usando la lógica de la teoría Dempster-Shafer.

**Belief** (Confianza) realiza una clasificación del Peso de la Evidencia Dempster-Shafer y extiende la lógica del análisis de mezclas, dando lugar a la habilidad de combinar nueva evidencia con conocimiento existente.

**HARDEN** (Endurecer) produce imágenes de decisión rígidas a partir de las producciones de los clasificadores blandos BAYCLASS, UNMIX, FUZCLASS, BELCLASS o MAHALCLASS eligiendo la clase que posee el valor máximo.

## Submenú de Análisis Hiperespectral de Imágenes (Hyperspectral Image Analysis Submenu)

**HYPERSIG** extiende la lógica del desarrollo de firmas al caso especial de datos hiperespectrales. HYPERSIG crea y muestra firmas hiperespectrales a partir de datos de sitios de entrenamiento o bien de archivos de curvas espectrales.

**ASDIDRISI** importa los datos del espectrómetro recogidos con el Dispositivo Espectral Analítico (ASD-Analytical Spectral Device).

**HYPERAUTOSIG** desarrolla automáticamente firmas para datos de imágenes hiperespectrales basándose en la lógica de Separación Espectral Lineal (Linear Spectral Unmixing).

**SCREEN** (Revisar) usa la autocorrelación espacial para controlar una serie hiperespectral de imágenes para detectar la presencia de ruido atmosférico significativo.

**HYPERSAM** es un clasificador rígido de mapas con ángulo espectral para datos hiperespectrales que usa un procedimiento de ángulo mínimo.

**HYPERMIN** es un clasificador rígido hiperespectral de distancia mínima específicamente diseñado para usar con firmas basadas en imágenes desarrolladas a partir de sitios de entrenamiento.

**HYPERUSP** provee clasificación no supervisada para datos de imágenes hiperespectrales.

**HYPEROSP** hace posible la clasificación hiperespectral de imágenes a través de un enfoque de proyección subespacial ortogonal.

**HYPERUNMIX** extiende las capacidades de Separación Lineal Espectral a juegos de datos hiperespectrales.

**HYPERABSORB** hace posible la clasificación hiperespectral de imágenes basándose en espectros de archivos y en la eliminación continua de áreas de absorción y la correlación de estas áreas en términos de adecuación y profundidad entre el espectro de biblioteca y los espectros de un juego de datos de imágenes.

## Submenú de Evaluación de la Exactitud (Accuracy Assessment Submenu)

La evaluación de la exactitud es un paso final importante en la clasificación tanto supervisada como no supervisada. Su finalidad es cuantificar la probabilidad de que aquello que Ud. trazó en un mapa es lo mismo que encontrará en el suelo. Esto es útil para comparar las técnicas de clasificación y para determinar el nivel de error que puede ser contribuido por la imagen de la cobertura terrestre en los siguientes análisis en los que se incorpore.

**SAMPLE** (Muestreo) crea esquemas de muestreo de puntos sistemáticos, aleatorios y estratificados aleatorios.

**ERRMAT** (Matriz de Errores) produce un análisis de matriz de errores de los datos de mapas categóricos comparados con la información de verdad terreno y clasifica errores de omisión y comisión, errores marginales y totales, Índice de Concordancia Kappa (Kappa Index of Agreement) por categoría e intervalos de confianza seleccionados.

## Menú de Reformar (Reformat Menu)

Los elementos del Menú de Reformar (Reformat Menu) permiten cambiar el tipo de datos y de archivo de un archivo, reorientar un archivo de imágenes o vectorial, cambiar el alcance del área de estudio, cambiar la resolución generalizar el nivel de detalle en el archivo, unir archivos y convertir archivos de raster a vectorial y viceversa. Para obtener más detalles, ver el capítulo sobre **Georeferenciamiento** (Georeferencing).

**CONVERT** (Convertir) cambia el tipo de datos o de archivo de un archivo de imágenes o vectorial.

**PROJECT** (Proyectar) vuelve a proyectar las coordenadas del sistema de referencia de archivos de imágenes o vectoriales.

**RESAMPLE** (Remuestreo) lleva a cabo una transformación a nivel local para la restauración geométrica de las imágenes y se usa para georegistrar una imagen en un sistema de referencia o en otro archivo.

**WINDOW** (Ventana) extrae una subárea rectangular de una imagen más grande para crear una nueva imagen más pequeña. Una función similar que permite guardar la ventana actualmente visualizada en una nueva imagen está disponible a través del cuadro de diálogo Guardar Composición de Mapas (Save Map Composition) del Diseñador (Composer) en el Sistema de Visualización (Display System).

**EXPAND** (Expandir) altera la resolución de imágenes raster por duplicación de píxeles.

**CONTRACT** (Contraer) altera la resolución de imágenes raster por reducción o acumulación de píxeles.

**CONCAT** (Concatenar) une múltiples imágenes o múltiples archivos vectoriales en una sola imagen o archivo vectorial.

**TRANSPOSE** (Transponer) rota una imagen 90 grados en cualquier dirección y puede revertir el orden de filas o columnas.

**RASTERVECTOR** convierte datos entre formatos raster y vectoriales.

**GENERALIZATION** (Generalización) se usa para generalizar datos vectoriales de puntos y líneas. Además puede generalizar datos raster uniendo regiones más pequeñas con regiones vecinas basándose en un umbral dado.

**LINTOPNT** extrae los vértices de un archivo vectorial de datos de líneas y los coloca en un archivo vectorial de datos de puntos.

## Menú de Entrada de Datos (Data Entry Menu)

IDRISI ofrece una variedad de herramientas para facilitar la entrada de datos. Además de los módulos de entrada de datos de este menú, Ud. podrá hallar funciones de conversión en el submenú Archivo/Importar (File/Import) para los datos existentes que no se encuentren en formato IDRISI. El capítulo **Desarrollo de Bases de Datos** (Database Development) también trata temas sobre la entrada de datos.

**CartaLinx** es un editor topológico vectorial completo y una herramienta de desarrollo de bases de datos espaciales también fabricada y distribuida por Clark Labs. Provee capacidades de digitalización de planos y en pantalla, y un amplio rango de herramientas para la edición de datos.

**Edit** (Editar) es la función del editor de texto de IDRISI para crear una variedad de archivos con formato ASCII relacionados con IDRISI.

**ASSIGN** (Asignar) asigna nuevos valores a una imagen.

**INITIAL** (Inicial) crea una imagen que contiene un solo valor.

**UPDATE** (Actualizar) asigna valores únicos a celdas específicas o a grupos rectangulares de celdas.

**UTMRef** facilita la creación de archivos de parámetros de sistemas de referencia basándose en el sistema Transversal Universal de Mercator, para usos posteriores con PROJECT.

Las opciones del **submenú Interpolación de Superficies** (Surface Interpolation) son idénticas a las del submenú Analysis / Surface Analysis / Interpolation y están descritas en esa sección. Los temas que rodean a la interpolación de superficies así como también las opciones disponibles en IDRISI se discuten más detalladamente en el capítulo **Interpolación de Superficies**.

**Database Workshop** (Taller para Bases de Datos) es un administrador relacional de bases de datos y se encuentra en el corazón de la ayuda de IDRISI para las colecciones de capas que conectan archivos de definición de características vectoriales con tablas de bases de datos. Database Workshop brinda la capacidad para crear, editar y analizar archivos de bases de datos en IDRISI. IDRISI utiliza Microsoft ADO y Access Jet Engines como la base para Database Workshop. Con esta función, uno puede realizar una gran variedad de operaciones de bases de datos incluyendo consultas, cálculos y visualización de mapas. Tanto la función Calculate (Calcular) como Filter (Filtrar) son complementadas con el uso de Structured Query Language (SQL) (Lenguaje Estructurado de Consultas). Para obtener más información, ver el capítulo sobre **Database Workshop** (Taller para Bases de Datos) en este volumen.

**IDRISI Explorer** (Explorador de IDRISI) es una herramienta con fines generales para administrar y explorar archivos y proyectos de IDRISI. Use el Explorador de IDRISI para establecer el ambiente de su proyecto, administrar sus archivos grupales, repasar los metadatos, visualizar archivos y simplemente organizar sus datos con herramientas tales como copy (copiar), delete (borrar), rename (cambiar nombre) y move commands (mover los comandos).

## Lista de Ventanas (Window List)

El menú Lista de Ventanas (Window List) ofrece una lista de todas las ventanas abiertas. Los diálogos abiertos aparecen en la lista con el nombre del módulo (por ejemplo, Composer) y las ventanas de mapas abiertas aparecen con el nombre de archivo que figura en el margen superior de la ventana de visualización del mapa. Al hacer clic sobre el nombre de una ventana en la lista, esa ventana se activará. Todas las capas de mapas y los diálogos abiertos se pueden cerrar desde el menú Window List.

## Menú de Ayuda (Help Menu)

El menú de Ayuda (Help) da acceso al Sistema de Ayuda (Help System) on-line de IDRISI.

**Contents** (Contenidos) lo conduce directamente al Sistema de Ayuda de IDRISI.

**Using Help** (Cómo usar la Ayuda) describe el Sistema de Ayuda de IDRISI. Aquí averiguará cómo acceder y navegar a través del Sistema de Ayuda. También se brinda información general sobre la pantalla y las funciones del Sistema de Ayuda y sobre cómo está organizada una entrada típica de los módulos de programa dentro del Sistema de Ayuda.



**IDRISI Quick Start** (Inicio Rápido) brinda la información básica necesaria para comenzar a usar el sistema IDRISI. Encontrará información sobre la pantalla de IDRISI, los módulos del programa, el Explorador de IDRISI y los cuadros de diálogo de IDRISI.

**What's New in the Selva Edition** (Lo Nuevo en la Edición Selva) brinda un panorama general sobre las funciones más nuevas desde la última edición.

**IDRISI Manual** (Manual de IDRISI) e **IDRISI Tutorial** (Tutorial de IDRISI) lo conducen directamente a los respectivos archivos PDF.

**Clark Labs Home Page** (Página Principal de Clark Labs) abre el sitio web de Clark Labs. **IDRISI Technical Support** (Soporte Técnico de IDRISI) lo conducirá a un formulario on-line en nuestro sitio web donde Ud. Puede describir su problema técnico y enviarlo como un e-mail a nuestro Personal de Soporte Técnico.

**About IDRISI Selva** (Acerca de IDRISI Selva) brinda información acerca de la licencia y los derechos de autor y también información general, incluyendo direcciones de contacto y números telefónicos.

## **Submenú de Inicio Rápido ESRI (ESRI Quick Start Submenu)**

La sección **ESRI Quick Start** del menú de ayuda otorga un acceso inmediato a la información sobre el Uso de ArcSIG/ArcView con IDRISI y al Sistema de Ayuda para los módulos comúnmente usados en la transferencia de datos entre los dos sistemas.

# CAPÍTULO 8 - Taller para Bases Datos

El Taller para Bases de Datos (Database Workshop) es el administrador de las bases de datos de IDRISI, y se encuentra en el corazón de la asistencia de IDRISI para colecciones de capas que unen archivos vectoriales de definición de características con tablas de bases de datos. IDRISI utiliza ADO (ActiveX Data Object) y Access Jet Engine de Microsoft como la base para el Taller para Bases de Datos. Con esta utilidad, se pueden llevar a cabo una amplia variedad de operaciones de bases de datos. Sin embargo la operación más importante es la interacción directa con las colecciones de tablas enlazadas: las consultas sobre bases de datos pueden mostrarse inmediatamente en la capa de mapa asociada, y las consultas sobre capas de mapas pueden unirse directamente con la tabla de datos. Además, los valores de los campos de las bases de datos pueden ser asignados o extraídos desde las capas raster. Cada uno de estos pasos se discute a continuación.

## Trabajando con Colecciones de Tablas Enlazadas

Una colección de tablas enlazadas consiste en un archivo vectorial de definición de características, una tabla de bases de datos y un archivo de enlace que asocia los otros dos. La colección se define usando el Collection Editor del menú de Archivo de IDRISI o desde la entrada del menú Establish Display Link (Establecer Enlace de Visualización) en el Database Workshop dentro del menú Query (Consultas)<sup>43</sup> El archivo de enlace contiene información acerca del archivo vectorial, del archivo de base de datos, de la tabla del archivo de base de datos (un archivo de la base de datos puede tener varias tablas), y acerca del campo de enlace para la colección. En una colección de tablas enlazadas cada campo (columna) en la base de datos, unido a la definición geográfica de las características en el archivo vectorial, se convierte en una capa de mapa. Éstas pueden ser visualizadas con el DISPLAY Launcher seleccionando la capa de interés que se encuentra abajo del nombre del archivo de colección, o tipeando el nombre “dot-logic” completo de la capa. El Taller para Bases de Datos ofrece varias formas adicionales para examinar estos datos. Una vez que se hace un enlace (link) de visualización, se pueden hacer consultas sobre las características de una capa de mapa unida para resaltar los registros en la base de datos, o bien se puede seleccionar un registro en la base de datos para resaltar esa característica en la capa del mapa vectorial.

## Iniciando el Taller para Bases de Datos

Para iniciar el Taller para Bases de Datos, haga clic sobre el botón de la barra de herramientas o seleccione su entrada en el menú Data Entry (Entrada de Datos) o Analylis/Database Query (Consulta de Bases de Datos y Análisis). Una vez abierto, si la capa seleccionada de la ventana de mapa activa es de una colección de tablas enlazadas, el Taller para Bases de Datos abrirá automáticamente esa tabla. De otro modo, use la opción File/Open (Archivo/Abrir) en el menú Database Workshop para seleccionar el archivo y la tabla de base de datos deseados.

## Cómo Visualizar Capas desde el Taller para Bases de Datos

Simplemente cliquee el mouse sobre cualquier registro (fila) del campo (columna) que Ud. desea ver y luego cliquee el icono Database Workshop Display (Visualización del Taller para Bases de Datos) de la barra de herramientas del Taller para Bases de Datos. El campo seleccionado será visualizado utilizando autoescala y el archivo de símbolos por defecto de IDRISI. Tenga en cuenta que cada una de estas acciones abre una nueva ventana de mapa,<sup>44</sup> por lo que resulta bastante probable que el sistema de visualización se sobrecargue si no tiene una memoria RAM de gran tamaño. Para evitar esto, cierre las ventanas periódicamente. La primera vez que abra una capa se le pedirá que indique el archivo de enlace a utilizar.

<sup>43</sup> Para más información sobre las colecciones, vea el capítulo **Capas de Mapas, Colecciones y Estructuras de los Datos**.

<sup>44</sup> Esto es poco evidente ya que cada ventana de mapa se superpone a la anterior. Recomendamos mover cada nueva ventana a un área no utilizada de la pantalla de manera que todas se puedan ver.

## Cómo Realizar Consultas sobre Bases de Datos usando un Filtro SQL



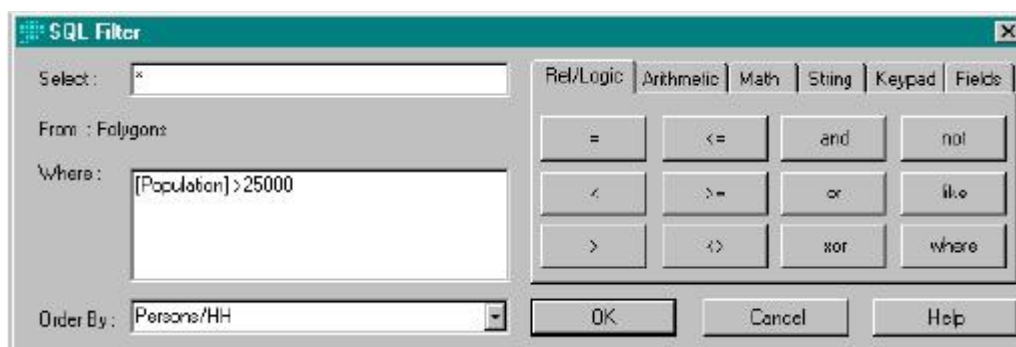
La consulta de bases de datos por atributo se consigue en el Taller para Bases de Datos *filtrando* la base de datos. Esto es simplemente la identificación de los registros con atributos que coinciden con nuestro criterio de consulta (es decir, filtro). Para consultar la tabla de base de datos activa, haga clic en el icono Filter Table (Filtrar Tabla) o elija la opción Filter Table del menú Query (consultas). Esto abre el diálogo SQL Filter que brinda una interfase simple para la construcción de una declaración de Lenguaje Estándar de Consultas (SQL).

La opción *Select* (Seleccionar) que se encuentra en la parte superior del diálogo del filtro especifica qué campos visualizar en el resultado. El asterisco por defecto indica todos los campos y es fino en la mayoría de los casos. Para especificar un subgrupo de campos, tipée sus nombres en este cuadro de entrada separados por comas. Recuerde que todos los nombres de los campos necesitan estar encerrados por corchetes si tienen espacios en sus nombres. (Para evitar ambigüedades, es un buen hábito colocar corchetes a todos los nombres de los campos).

El cuadro de entrada *Where* (Donde) es donde se construye la parte principal del filtro. Las opciones de las fichas de la derecha facilitan la colocación de elementos de filtro. El SQL necesita espacios a ambos lados de cada operador. Si selecciona los elementos en lugar de tipearlos, IDRISI se asegura que sea así. Observe además que cualquier cláusula SQL válida puede ser ingresada; por lo que Ud. no está limitado a las opciones que se muestran en las fichas.

El cuadro de entrada *Order By* (Ordenar Por) es opcional. Solamente almacena los resultados de la consulta según el campo elegido.

El filtro se ejecuta haciendo clic en OK. El Taller para Bases de Datos solo mostrará los registros que coinciden con el criterio de consulta. Los registros que no coinciden con el criterio permanecen en la base de datos, pero están escondidos. (Elimine el filtro para restaurar la base de datos completa – ver abajo.)



### Mapeo de los Registros Filtrados

Cuando se ejecuta un filtro, IDRISI verifica todas las ventanas de mapas abiertas para ver si alguna contiene una capa activa que está unida a la base de datos que ha sido filtrada. Si es así, los resultados de la consulta se mostrarán automáticamente como un mapa Booleano con las características que coinciden con el criterio en color rojo y el resto en negro.

### Eliminando el Filtro



Para eliminar cualquier filtro, elija el icono Remove Filter (Eliminar Filtro) de la barra de herramientas o seleccione la opción desde el menú Query.

### Consultas por Ubicación



Cuando una ventana de mapa contiene una capa activa (la que está resaltada en el Diseñador) unida a una base de datos, Ud. puede usar el cursor en Modo Consultas (Inquiry- de la barra de herramientas de IDRISI) para realizar una consulta de base de datos por ubicación. Cuando hace clic en una característica del mapa, el Taller para Bases de

Datos ubicará automáticamente el registro correspondiente en la base de datos. El registro encontrado se indica con una marca triangular en el borde izquierdo del registro en la visualización de la tabla.

## Otras Operaciones de las Bases de Datos

### Calculando los Valores de los Campos

Además de consultar la base de datos, a veces es necesario crear nuevos campos, importando valores externos o calculando nuevos valores a partir de los campos existentes. Por ejemplo, uno puede calcular un nuevo campo de valores de la densidad poblacional basado en campos existentes de población y área. La opción Calculate Field Values (Calcular los Valores de los Campos) del menú Query (o en su icono de la barra de herramientas del Taller para Bases de Datos) genera un diálogo SQL similar al del Filtro SQL. En este caso, facilita la construcción de una operación SQL UPDATE SET para calcular nuevos valores para un campo como una función de ecuación matemática o lógica. En el cuadro de entrada SET, seleccione el campo de interés. Luego ingrese la ecuación en el cuadro de entrada principal después del signo “=” usando las opciones de las fichas como ayuda. A igual modo que el Filtro, puede ingresarse cualquier cláusula válida – no está limitado a las opciones especificadas en las fichas de control.

### Consultas SQL Avanzadas en Tablas Relacionales

Un editor avanzado SQL también se encuentra disponible en el menú Query. Puede usarse para realizar comandos más complicados en la tabla activa y en las tablas del archivo de la base de datos activa. Las Consultas pueden guardarse en un archivo de texto. Infórmese con un texto SQL para los comandos avanzados.

### Buscando Registros Específicos

La opción Find Next (Encontrar Próximo) del menú Query (o en su icono de la barra de herramientas del Taller para Bases de Datos) provee una manera simple para encontrar registros. La opción “=” busca la próxima combinación exacta, mientras que la opción “like” busca combinaciones aproximadas. La segunda opción sólo es válida con campos secuenciales de texto y utiliza una caracteres wildcard. Aquí se exponen algunos ejemplos:

like “*ks”	encuentra el próximo registro que termina en “ks”
like “ks*”	encuentra el próximo registro que comienza con “ks”
like “*ks*”	encuentra el próximo registro con “ks” en cualquier lugar dentro de la secuencia del texto
like “k?s”	busca cualquier caracter en segunda posición
like “k#s”	busca cualquier dígito (no una letra) en segunda posición
like “[a-d]*”	encuentra el próximo registro que comienza con una letra de la <i>a</i> a la <i>d</i> .
like “[!a-d]*”	encuentra el próximo registro que no comienza con una letra de la <i>a</i> a la <i>d</i> .

### Búsqueda (Sorting)

Para buscar los registros de la base de datos según los valores de un campo particular, haga clic con el mouse sobre cualquier registro de ese campo y luego un clic en el botón de búsqueda ascendente o descendente de la barra de herramientas del Taller para Bases de Datos (Database Workshop).

### Ingresando o Modificando Datos

Específicamente necesitará cambiar al Modo Edición (Edit Mode) antes de poder ingresar o modificar que cualquier valor de celda en la base de datos. Esta acción previene cambios accidentales en los valores de datos. Active el modo edición eligiendo la opción del menú Edit o haciendo clic en el botón de estado Edit Mode. La grilla cambia de color cuando se cambia al modo edición. Varias de las opciones de la barra de herramientas permanecen desactivadas hasta que se quite el modo edición. Por lo tanto, debe abandonar el modo edición ni bien termine de ingresar los datos. Para hacer esto, elija la opción del menú Edit o haga clic en el botón de estado Edit Mode.

## Modificando la Estructura de la Tabla

La estructura de la tabla puede modificarse (es decir, agregar, renombrar o eliminar campos y agregar o eliminar registros) del menú Edit. Sin embargo, esto no puede lograrse si otros “usuarios” tienen acceso a la tabla. Toda ventana de mapa que esté enlazada a esta base de datos es considerada como un usuario. Por ello, necesitará cerrar todas estas ventanas de mapas para poder alterar la estructura de la tabla.

## Cómo Asignar y Extraer Datos de las Capas Raster

El Taller para Bases de Datos brinda medios muy simples para asignar datos de campo a una capa raster o para extraer datos de una capa raster y colocarlos en un campo de base de datos. Para asignar datos de campo a una capa raster, use el comando Export/Raster Image (Exportar/Imagen Raster) del menú Archivo (File) en el Taller para Bases de Datos. Debe establecerse un enlace o unión y especificarse la información de fila y columna. Por defecto, las coordenadas x e y de la nueva imagen raster serán extraídas del archivo vectorial enlazado. Para extraer datos de una imagen raster, use el comando Export/Raster Image del menú Archivo en el Taller para Bases de Datos. Un archivo raster de definición de características deberá ser especificado representando los ID's (identificadores) en la imagen raster de definición de características usada en la extracción. Estos identificadores deben coincidir con uno de los campos (el campo enlazado) de la base de datos.

## Cómo Asignar e Importar Datos de Capas Vectoriales

Los archivos vectoriales pueden ser creados o incorporados desde el menú Archivo en el Taller para Bases de Datos. Primero debe establecerse un enlace de visualización. Luego, para importar archivos vectoriales, simplemente seleccione el comando Import/Vector File (Importar/Archivo Vectorial) del menú. Se agregará una nueva tabla a la base de datos abierta que contiene los valores del archivo vectorial. También se creará un nuevo campo ID. Para exportar un campo hacia un archivo vectorial, resalte el campo de interés y seleccione el comando Import/Vector File del menú. Las características vectoriales creadas estarán basadas en el archivo vectorial enlazado especificado en el archivo vectorial de la colección.

## Exportación e Importación

El Taller para Bases de Datos también brinda opciones seleccionadas de importación y exportación en el menú Archivo. Los formatos por defecto aceptados son xBase, Microsoft Excel, archivos delimitados por comas (.csv) y archivos de texto.

# CAPÍTULO 9 - Cómo Realizar Consultas sobre Bases De Datos en IDRISI

Quizás la más fundamental de las operaciones analíticas llevadas a cabo en SIG es simplemente la consulta sobre bases de datos, en la que formulamos preguntas de la base de datos y examinamos los resultados en forma de mapa. Con una base de datos espacial, se pueden formular dos tipos de preguntas: “¿Qué ubicaciones tiene este atributo?” y “¿Cuál es el atributo en esta localización?”. La primera es conocida como *consulta por atributo* y la segunda como *consulta por localización*.

## Consulta por Atributo

La **consulta por atributo** (query by attribute) puede ser realizada de varias maneras, dependiendo de la geografía de las capas. Si ud. está trabajando con una sola geografía (ej.: campos de cultivo, provincias) definida por un archivo vectorial para el cual ud. tiene muchos atributos en una base de datos, la consulta sobre la base de datos será completada enteramente en el Database Workshop (Taller para Bases de Datos) utilizando un filtro SQL. Luego, los resultados pueden ser vinculados a un archivo vectorial para su visualización o pueden ser asignados a una imagen raster de definición de características para una posterior visualización.

Por ejemplo, si tuviese un mapa de los países del mundo y muchos atributos para cada país guardados en una base de datos, entonces ud. podría realizar una consulta como “Encontrar todos los países donde los ingresos anuales medios per capita sean menores a \$5000 y la tasa de alfabetización sea mayor al 60%”. Las condiciones de la consulta podrían ser usadas en un filtro SQL en el Database Workshop, y el resultado podría ser vinculado al archivo vectorial original de definición de características en DISPLAY Launcher (Lanzador de la Visualización). Si se debe crear un nuevo archivo de imagen raster, los atributos pueden ser asignados a una imagen raster de definición de características desde el Database Workshop.

Sin embargo, si las geografías de los atributos de interés no son las mismas o si los atributos sólo existen como capas de imagen, hay dos pasos a seguir. Primero, se seleccionan en cada capa las características que cumplen con las condiciones especificadas. Normalmente, esto implica el uso de RECLASS (reclasificar) o ASSIGN (asignar). Luego, aquellos datos seleccionados son utilizados en una operación de superposición realizada con el módulo OVERLAY para encontrar las ubicaciones que cumplen con todas las condiciones. (Ambos pasos pueden llevarse a cabo con un solo comando en Image Calculator, pero detrás de la interfase, los pasos individuales siguen realizándose en secuencia).

Por ejemplo, ud. podría preguntar “¿Dónde están todas las ubicaciones que poseen uso residencial del terreno y se encuentran dentro de media milla de distancia de la ruta principal de los aviones que despegan de un aeropuerto determinado?”. En este caso, la geografía del uso del terreno y aquella de las rutas de vuelo para el aeropuerto no son las mismas. Se crearía una imagen Booleana (ceros y unos solamente) para cada condición con RECLASS o ASSIGN y luego éstas serían combinadas en una operación de multiplicación OVERLAY. La imagen resultante solamente tendría el valor de una donde se encuentran ambas condiciones:

<u>Imagen de Entrada 1</u>	X	<u>Imagen de Entrada 2</u>	<u>= Imagen de Salida</u>
0		0	0
1		0	0
0		1	0
1		1	1

La reclasificación y la superposición son fundamentales para realizar consultas por atributo en SIG. En IDRISI, RECLASS y ASSIGN son las herramientas utilizadas para realizar consultas sobre bases de datos acerca de un solo atributo, y pueden usarse para producir imágenes Booleanas tanto directamente como a través de Image Calculator.

Mientras que RECLASS y ASSIGN pueden usarse para producir resultados similares, existen varias diferencias importantes entre estos módulos. Aún en los casos donde cualquiera puede ser usado, generalmente uno resultará más fácil de usar que el otro. La elección se volverá más evidente a medida que ud. se familiarice con las características de los dos módulos.

RECLASS trabaja sobre un archivo de imagen. La imagen original puede tener valores byte, enteros o reales. Sin embargo, los nuevos valores asignados sólo pueden ser byte o enteros. Los valores originales pueden ser especificados como valores individuales o como escalas de valores. Esta información es ingresada en el cuadro de diálogo de RECLASS. Todos los valores excluidos de las escalas especificadas de reclasificación permanecerán sin cambios, excepto los valores reales que serán automáticamente redondeados a su número entero más cercano.

Con ASSIGN, se requiere un archivo de imagen de definición de características y un archivo de valores de atributo. Este último es comúnmente creado con Edit o importado desde una hoja de cálculo o un paquete de software estadístico. Los valores de datos en la imagen de definición de características deben ser byte o enteros. Sin embargo, el nuevo valor a asignar puede ser byte, entero o real. Tanto los valores viejos como los nuevos deben ser especificados como números individuales, no como escalas. Los valores viejos y los nuevos son ingresados en un archivo de valores en lugar de ingresarlos en el cuadro de diálogo de ASSIGN. A todo valor original no especificado en el archivo de valores se le asignará automáticamente el nuevo valor cero en la imagen de salida.

Cuando la consulta implique más de un atributo, es necesario usar OVERLAY. (Nuevamente, el usuario podrá elegir utilizar OVERLAY directamente o a través de Image Calculator). Por ejemplo, para encontrar todos los terrenos agrícolas sobre el tipo de suelo 6 es necesario que primero aislemos de la capa de suelos el tipo de suelo 6 como una imagen Booleana, y el terreno agrícola como una imagen Booleana de la capa de usos del terreno. Luego, estas dos imágenes Booleanas son superpuestas por medio de la operación de multiplicación para encontrar todos los casos donde haya tipo de suelo 6 Y (AND) agrícola.

De forma similar, la opción máxima de OVERLAY puede utilizarse para producir el resultado Booleano OR:

<u>Imagen de Entrada 1</u>	Max	<u>Imagen de Entrada 2</u>	<u>= Imagen de Salida</u>
0.00		0.00	0.00
1.00		0.00	1.00
0.00		1.00	1.00
1.00		1.00	1.00

Todas las operaciones lógicas pueden lograrse de manera similar a través de operaciones simples sobre imágenes Booleanas. Por ejemplo, la operación Booleana XOR (OR exclusiva) puede realizarse con una operación de adición, seguida por una reclasificación de todos los valores diferentes de 1 a 0. Al desarrollar modelos que necesitan este tipo de lógica, generalmente es útil construir una tabla como las mostradas anteriormente para determinar el tipo de operaciones de IDRISI necesarias.

En Image Calculator, estos análisis son construidos como expresiones lógicas. Mientras que el Image Calculator a menudo brinda una interfaz más rápida y fácil, existen ventajas, particularmente para aquellos que recién se inician en el manejo de SIG, en usar los módulos directamente y realizar cada etapa individualmente. Esto permite evaluar cada etapa en el proceso para poder detectar los errores en la lógica más fácilmente. La utilización de los módulos en forma individual también permite al usuario familiarizarse más con su operación, facilitando así el uso de estos módulos fuera de los límites de la consulta sobre bases de datos.

## Consulta por Ubicación

La consulta por ubicación se logra con mayor facilidad en IDRISI a través de la herramienta Cursor Inquiry en Display System (Sistema de Visualización). Seleccione el icono Cursor Inquiry y con su cursor colocado sobre la ubicación deseada, haga clic en el botón izquierdo del mouse. El valor de datos implícito para esa ubicación será visualizado en la pantalla.

La consulta por ubicación puede extenderse para incluir una consulta sobre varios archivos raster simplemente con la creación de un archivo de grupo de imagen raster (.rgf) que contenga todos los archivos relacionados con un grupo particular. Una consulta por ubicación en cualquiera de las imágenes agrupadas proporcionará información acerca del valor del píxel en esa ubicación para todas las imágenes del grupo. De manera similar, la consulta por ubicación en un archivo vectorial que ha asociado la base de datos con archivos de enlaces vectoriales (.vtx), proporcionará todos los valores de campo vinculados de la base de datos para el objeto consultado. Los archivos de grupo y de enlace son creados con Collection Editor que se encuentra en el menú File (Archivo).

Otras herramientas para la consulta sobre bases de datos por ubicación incluyen PROFILE (Perfil), QUERY (Consulta), WINDOW (Ventana) y EXTRACT (Extraer). Cada una de éstas brinda resultados acerca de los atributos encontrados en la ubicación de las características de entrada.



# CAPÍTULO 10 - Herramientas de Modelación de IDRISI

Uno de los roles fundamentales de los SIG es su papel en el desarrollo, prueba y utilización de modelos – modelos de adecuación, modelos de erosión del suelo, modelos del crecimiento urbano, etc. IDRISI ofrece un extenso juego de herramientas para la modelación, dando lugar a un amplio rango de niveles de experiencia. La más importante es Macro Modeler, un ambiente modelador gráfico que combina las potencialidades de las capacidades extensivas con la facilidad de uso. El Image Calculator (calculadora de imágenes) provee una entrada de ecuación rápida valiéndose de una interfase calculadora familiar para una modelación más simple que usa capas SIG basado en ecuaciones. La tercer utilidad es un lenguaje de escritura (.iml) macro (macro scripting language) que se ofrece en gran medida para aplicaciones de legado (esta era la forma original de herramienta modeladora ofrecida en una de las primeras versiones de IDRISI). Finalmente, se encuentra el IDRISI API, una interfase COM industrial estándar que brinda acceso al interior del sistema IDRISI para las aplicaciones y el desarrollo de interfases más exigentes. API requiere un ambiente de programación compatible con COM como Visual C++, Delphi o Visual Basic.

## Modelador Macro de IDRISI (Macro Modeler)

El Modelador Macro de IDRISI es un ambiente gráfico en el que Ud. puede ensamblar y ejecutar análisis multipasos. Los archivos de entrada, como las imágenes raster, las capas vectoriales y los archivos de valores de atributo, están unidos a los módulos de IDRISI, los que al mismo tiempo están unidos a archivos de salida de datos. El resultado es un modelo gráfico, similar a los modelos cartográficos descritos en los Ejercicios Introdutorios a SIG del Tutorial. Un modelo puede ser tan simple o complejo como se desee. La Figura 10-1 muestra un modelo de mapeo de adecuación simple.

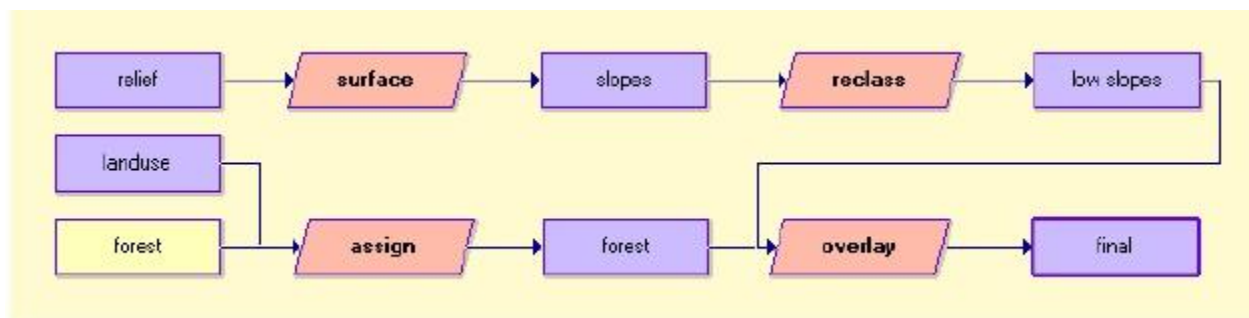



Figura 10-1

## Construcción de Modelos

Para trabajar con el Modelador Macro, presione su icono en la barra de herramientas o selecciónelo desde el menú Modeling. Esto produce un espacio de trabajo especial con la forma de una página gráfica con un menú y una barra de herramientas separados. La construcción de un modelo requiere colocar de símbolos sobre la página gráfica para los archivos de datos y para los módulos y luego unir estos elementos del modelo con conectores. Para colocar un elemento, haga clic en su icono (mostrado en la Figura 10-2) o elija el tipo de elemento desde el menú Macro Modeler, luego elija el archivo o la operación específica de la lista de selección brindada. (Observe que no todos los módulos de IDRISI están disponibles para usar en el Modelador Macro.<sup>45</sup>) Para conectar elementos, presione el icono conector, luego haga clic sobre uno de los elementos y arrastre el cursor sobre el otro elemento y suéltelo encima de éste. Es necesario conectar los elementos en el orden apropiado porque el Modelador Macro asume que el proceso fluye desde el elemento que Ud. cliqueó primero hacia el elemento sobre el cual Ud. soltó el cursor. Para borrar cualquier elemento, primero presione ese elemento y luego haga clic en el icono delete (borrar) o presione la tecla suprimir del teclado.

<sup>45</sup> Los módulos del menú de Procesamiento de Imágenes así como también todo módulo que no crea archivos de salida, como REGRESS, no funcionan en el Modelador Macro.



**Figura 10-2**

Siempre que un módulo se inserta en el modelo, éste es colocado con el elemento de datos de salida apropiado para esa operación. Los nombres por defecto de archivos temporarios se asignan a los archivos de salida. Un clic derecho sobre el símbolo de un archivo de datos cambia el nombre del archivo. Los nombres de archivos largos son justificados a la izquierda. Para ver el nombre entero del archivo, detenga el cursor sobre el gráfico del elemento para que aparezca un cuadro de texto con el nombre entero del elemento. Los nombres de archivos son almacenados sin rutas. Los archivos de entrada pueden existir en cualquier carpeta del proyecto actual (especificado con el módulo Data Paths) mientras que los archivos de salida intermedios y finales siempre son guardados en la carpeta de trabajo (Working Folder).

Para especificar los parámetros para el módulo, haga un clic derecho sobre el símbolo del módulo. Esto abre el diálogo de parámetros del módulo. Presione cualquier parámetro para ver y elegir otras opciones. Ingrese en el Sistema de Ayuda mpara obtener información detallada acerca de las variadas opciones haciendo clic en el botón Help del diálogo de parámetros.

Los submodelos son construidos por el usuario y encapsulados subsecuentemente en un solo elemento de comando. Cuando un modelo es almacenado como un submodelo, se crea un diálogo de parámetros para el submodelo en el cual el usuario provee las leyendas para todas las entradas y salidas del modelo. Un submodelo consiste en un archivo de parámetros de submodelo (.ims) y en su archivo de modelo macro (.imm). Cuando un submodelo se coloca como un elemento comando en un modelo, el Modelador Macro sabe cuántos y qué tipos de archivos de entrada se necesitan para ejecutar el submodelo y qué tipos de archivos de salida deben producirse. Por ejemplo, se puede crear un submodelo que amplía una sola imagen y luego la exporta a una imagen JPG. Este modelo incluiría STRETCH y JPGIDRIS, pero el submodelo sólo necesitaría la imagen de entrada y la de salida. El usuario puede cambiar los elementos de los datos de entrada y salida de un submodelo a través del diálogo de parámetros, pero las configuraciones para los comandos del módulo que son parte de un submodelo deben cambiarse abriendo el modelo a partir del cual fue creado el submodelo. Luego se hacen los cambios y por último se vuelve a guardar el submodelo. Los submodelos no sólo simplifican los procesos multipasos, sino que también constituyen elementos importantes cuando los modelos tienen secciones que deben repetirse. Esto se discute con profundidad más adelante.

Los modelos se almacenan en un archivo Macro Model de IDRISI (.imm). Este archivo preserva todos los aspectos del modelo, incluyendo el trazado gráfico. El archivo puede abrirse y modificarse con el Modelador Macro. La descripción gráfica del modelo puede copiarse (como un archivo ".bmp") en el portapapeles del sistema operativo, y luego pegarse en otro procesador de texto o software de gráficos. El gráfico también se puede imprimir. Los iconos de la barra de herramientas para el manejo del archivo del Modelador Macro se muestran en la Figura 10-3.



**Figura 10-3**

Los modelos se pueden ejecutar en cualquier paso de su construcción. El Modelador Macro primero hace una verificación para ver si alguna de las imágenes de salida ya existe. Si es así, muestra un mensaje que indica cuál de los archivos existe y pregunta si se desea continuar. Si contesta Yes (o Yes to All – Sí a todo) borrará el archivo de salida existente antes de ejecutar el modelo. Si contesta No, impedirá que el Modelador Macro ejecute el modelo.

Mientras se ejecuta el modelo, el elemento del modelo que está siendo procesado actualmente se pone verde. Para detener un modelo en cualquier momento mientras se está ejecutando, haga clic en el icono stop. El modelo terminará el proceso que está llevando a cabo en ese momento y luego se detendrá.

La última producción creada por el modelo se mostrará automáticamente. Las imágenes intermedias pueden visualizarse haciendo clic en el icono display (visualizar) en la barra de herramientas del Modelador Macro, y luego en el símbolo de la capa de datos. A los metadatos se puede acceder, para cualquier capa de datos, haciendo clic en el icono Metadata de la barra de herramientas del Modelador Macro y luego en el símbolo de la capa de datos. Los iconos de la barra de herramientas para estas funciones se muestran a continuación en la Figura 10-4.




**Figura 10-4**

## DynaGroups

Dos capacidades distinguibles del Modelador Macro son sus utilidades DynaGroups que facilitan la ejecución del mismo modelo en múltiples capas de datos y DynaLinks que construyen modelos iterativos en los cuales la producción de un proceso se transforma en la entrada para la próxima iteración del proceso.

Un DynaGroup es un archivo de grupo raster o un archivo de serie de tiempo que se utiliza en el Modelador Macro para que cada miembro del grupo se use para producir un elemento de salida. Contraste esto con el uso de un archivo de grupo como una entrada de datos normal para el Modelador Macro en el cual un archivo de grupo usado como entrada produce un solo elemento de salida como sucede con el módulo COUNT. Se puede usar más de un DynaGroup en un proceso. El módulo OVERLAY (superposición) por ejemplo, necesita dos imágenes raster como entrada y produce una sola imagen raster de salida. Si se usan DynaGroups como las dos entradas, entonces el Modelador Macro primero verificará que cada grupo tiene el mismo número de miembros y luego ejecutará OVERLAY usando las imágenes correspondientes de los dos archivos de grupo. Si se usa una sola capa raster como una entrada y un DynaGroup como otra de las entradas para OVERLAY, entonces el Modelador ejecutará OVERLAY con la imagen raster sola y cada miembro del grupo a la vez. En todos los casos el número de imágenes de salida es igual al número de miembros del archivo DynaGroup. En el Sistema de Ayuda se describen muchas opciones para nombrar los archivos de salida.

Además, se construye automáticamente un archivo de grupo de los archivos de salida. En el modelo que se ilustra en la Figura 10-5, dos DynaGroups son usados como entrada para una operación de superposición. La producción será el número de imágenes raster contenidas en los DynaGroups de entrada más un archivo de grupo raster.




**Figura 10-5**

## DynaLinks

Los DynaLinks se usan para ejecutar un modelo iterativamente. Un elemento de datos de salida se une con elemento inicial de datos de entrada usando un DynaLink. Esto indica que cuando el modelo realice la segunda iteración, el nombre del archivo de salida unido debe reemplazar el nombre del archivo de entrada unido. Un dynalink sólo puede ser conectado a una capa de datos inicial, es decir, una que no tiene ningún conector unido a su lado izquierdo. El Modelador Macro pregunta cuántas iteraciones se realizarán y si debe mostrarse cada salida terminal del modelo o sólo la salida terminal de la iteración final. La salida final de un modelo que incluye un DynaLink es una sola capa raster. El modelo mostrado en la Figura 10-6 usa un DynaLink. Cuando se ejecuta el modelo, el Modelador Macro pregunta el número deseado de iteraciones. Supongamos que en este caso queremos 5 iteraciones.

El archivo de entrada llamado Banda3 es filtrado para crear una imagen de salida llamada filtrado x5\_01. En la segunda iteración, el archivo filtrado x5\_01 se filtra para producir el archivo filtrado x5\_02. Este archivo luego es sustituido de vuelta como la entrada para la próxima operación de filtrado y así sucesivamente. Al final de la 5ta iteración la imagen final se llama filtrado x5. Las imágenes intermedias (Ej.: filtrado x5\_03) no se borran automáticamente hasta que el módulo se ejecute nuevamente.




**Figura 10-6**

Tenga en cuenta que el modelo se ejecuta entero durante cada iteración, aún cuando la substitución ocurre cerca del final. Para ejecutar sólo una porción del modelo iterativamente, use un submodelo que contenga un DynaLink (ver abajo).

## Usando DynaGroups, DynaLinks y Submodelos Juntos

Cuando se usan DynaGroups y DynaLinks en el mismo modelo, el número de miembros en el DynaGroup define el número de iteraciones que se va a ejecutar. Cada iteración del modelo introduce un nuevo miembro DynaGroup. La producción de un modelo que contiene ambos elementos es una sola capa de datos. La Figura 10-7 ilustra un modelo simple en el cual un grupo de archivos raster es sumado usando un DynaGroup y un DynaLink. En la primera iteración, la capa inicial BLANK (la cual es simplemente una imagen con valor 0 en todas partes) se usa con el primer miembro DynaGroup en una operación de Adición de Supercapa (Overlay Addition). Esto produce el archivo temporario SUM\_01. Éste luego es sustituido de vuelta en el lugar de la capa BLANK para la segunda iteración. El número de iteraciones es igual al número de imágenes del DynaGroup.

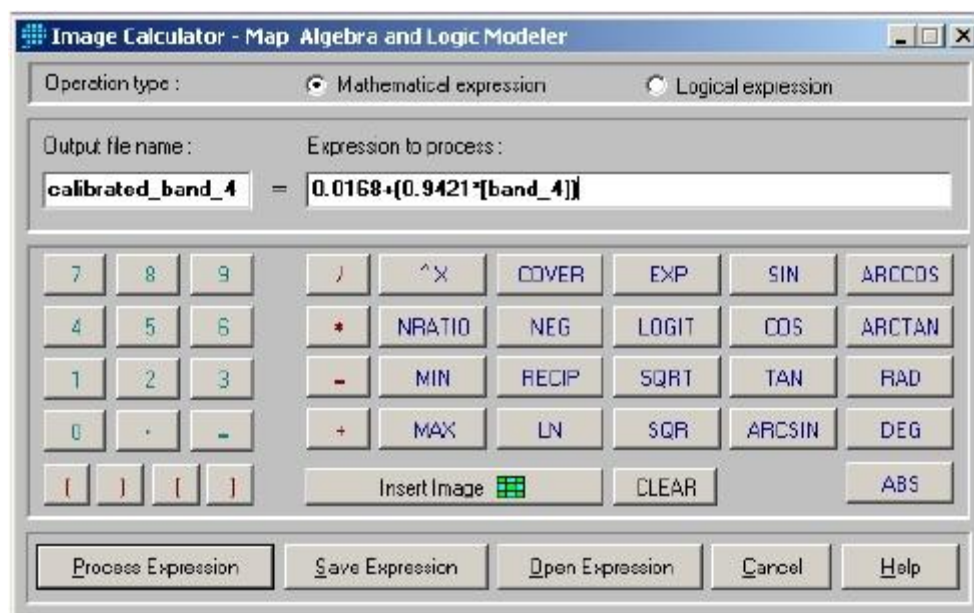


**Figura 10-7**

Para repetir sólo una porción del modelo, cree un submodelo para la porción que debe ser repetida. Cuando Ud. Ejecute el modelo, aparecerá un cuadro de diálogo para cada submodelo preguntándole el número de iteraciones para ese submodelo.

## Calculadora de Imágenes (Image Calculator)

El Calculadora de Imágenes es una herramienta de cálculo para procesar ecuaciones rápidamente usando capas de imágenes raster. Las ecuaciones pueden ser almacenadas y editadas en otro momento. Es extremadamente fácil de usar ya que funciona exactamente como una calculadora científica y ofrece la funcionalidad generalmente asociada a las calculadoras. El único requerimiento especial es que todos los archivos de imágenes deben especificarse usando corchetes como delimitadores. Por ejemplo, en la Figura 10-8, una banda de imagen calibrada se crea multiplicando sus valores por una ganancia de 0,9421 y luego sumando una compensación de 0,0168. Se puede acceder a ella a través de su icono en la barra de herramientas o desde varias ciertas entradas de menú: bajo las secciones Mathematical Operators (operadores matemáticos) y Database Query (consulta de bases de datos) del menú GIS Analysis (Análisis SIG) y del menú Modeling (modelación).



**Figura 10-8**

## Sintaxis para Macros

El Modelador Macro y el Calculadora de Imágenes proveen interfaces muy simples y directas para crear modelos. Sin embargo, también se aceptan los lenguajes de sintaxis para macros, principalmente para avalar las aplicaciones de legado de las primeras versiones de IDRISI. Una sintaxis para macros es un archivo ASCII que contiene los nombres de los módulos y los parámetros para la secuencia de los comandos que van a ser ejecutados. No provee la capacidad de batch (proceso encadenado) automático (aunque se puede copiar, pegar y editar rápidamente para lograr esto) ni de repetición.

Se pueden encontrar instrucciones específicas en el Sistema de Ayuda on-line sobre el formato de la sintaxis macro para cada módulo. Estas instrucciones se pueden colocar en un archivo ASCII con una extensión “.IML” (sigla que significa “IDRISI Macro Language”). Por lo general, esto se realiza con el módulo Edit. Si se elige guardarlo como archivo de tipo Macro, la extensión correcta del nombre de archivo se agregará automáticamente.

Tenga en cuenta que algunos módulos no poseen una versión de sintaxis macro. Estos son generalmente módulos que no producen un archivo resultante (Ej.: Explorador de Archivos IDRISI) o módulos que requieren interacción con el usuario (Ej.: Edit). En el menú, cualquier módulo escrito por completo en letra mayúscula puede usarse en un macro.

IDRISI graba todos los comandos que Ud. ejecuta en un archivo de texto ubicado en la carpeta de trabajo. Este archivo se llama archivo LOG. Los comandos son grabados en un formato similar al formato de la sintaxis para macros. A veces puede ser más eficiente editar un archivo LOG para obtener el formato macro que tipear comandos macro desde cero. Para hacer esto, abra el archivo LOG en Edit y modifíquelo para obtener el formato de archivo macro. Luego guárdelo como un archivo macro.

Observe que siempre desde un cuadro de diálogo o un macro, la sintaxis utilizada para generar cada imagen de salida se almacena en el campo Lineage de esa imagen en su archivo de documentación. Esto se puede ver con la utilidad Metadata y se puede copiar y pegar en un archivo macro usando las teclas CTL+C para copiar el texto resaltado en Metadata y las teclas CTL+V para pegarlo en el archivo macro de Edit.

El cuadro de diálogo Run Macro, en el menú File, pregunta por el nombre del macro que se quiere ejecutar y por los parámetros de sintaxis macros que deben pasarse al mismo archivo macro. Este último cuadro puede dejarse en blanco si no hay parámetros.

Cada línea en un macro se completa en secuencia porque la imagen resultante de un comando a menudo se usa como entrada para un comando siguiente. Además, si se abre más de un macro, el primer macro lanzado es completado antes de que comience el segundo.

## Estructura del Archivo Macro

Los archivos Macro de IDRISI aceptan la siguiente sintaxis.

1. Los módulos de IDRISI en modo de línea de comando. El siguiente es un ejemplo de una línea válida en un archivo IML:

```
OVERLAY x 3 *soilsuit*slopsuit*suitland
```

La x después del nombre del módulo indica que el modo de línea de comando para macro está solicitado. *Todos los parámetros después de la x están separados por asteriscos.* Pueden darse, como en el ejemplo de arriba, nombres de archivos cortos. En este caso, el macro buscará el tipo de archivo apropiado primero en la carpeta de trabajo y luego en cada carpeta de recursos en el orden en que están listadas en el archivo de proyecto actual. Los nombres de archivos largos, y las rutas completas, también se pueden dar en la sintaxis para macros, Ej.:

```
OVERLAY x 3*c:\data\soil.rst*c:\data\slopes.rst*c:\output\suitable_land.rst
```

2. El procesador macro acepta sintaxis variables usando el formato % # (familiar a los usuarios de DOS). Por ejemplo, la línea anterior podría modificarse de este modo:

```
OVERLAY x 3%1*%2*%3
```

En esta modificación, %1, %2 y %3 reemplazan los tres primeros parámetros de la sintaxis especificados en el cuadro de texto Macro Parameters del cuadro de diálogo Macro.

3. Aplicaciones externas. Cualquier aplicación no perteneciente al IDRISI puede llamarse desde un archivo IML. La sintaxis es de la siguiente manera:

```
CALL c:\modelos\suelcam.exe sueltipo.rst
```

4. Otros archivos IML. Es posible ejecutar otros archivos IML desde un archivo IML principal usando el comando BRANCH. La sintaxis para tal operación es:

```
BRANCH [Nombre del archivo IML] [Parámetros de Línea de Comando]
```

El nombre del archivo IML es el nombre corto del archivo IML que se va a llamar (Ej.: sin extensión). Los parámetros de la sintaxis son opcionales.

## API IDRISI

IDRISI ha sido diseñado como un Servidor de Automatización OLE que utiliza tecnología COM Object (es decir, un Servidor COM). Como consecuencia, es posible usar lenguajes de desarrollo de alto nivel tales como Delphi, Visual C++, Visual Basic o Visual Basic para Aplicaciones (VBA) como lenguajes macro para controlar el funcionamiento de IDRISI. Además, Ud. puede crear aplicaciones sofisticadas de Controlador de Aplicaciones OLE que poseen un control total sobre el funcionamiento de IDRISI. Entonces, Ud. va a usar API en situaciones en las que desee:

--crear modelos complejos que necesitan las estructuras de control extensivas de un lenguaje informático de alto nivel (como muchos modelos dinámicos);

--crear aplicaciones hechas a medida, tal vez para ser distribuidas a otras personas,

--crear interfaces hechas a medida.

La cualidad de IDRISI como Servidor de Automatización OLE se registra con Windows automáticamente cuando IDRISI se inicia por primera vez en su sistema. Por lo tanto, si Ud. ha instalado IDRISI y lo ha ejecutado al menos una vez, automáticamente tiene acceso completo a API. El Servidor de Automatización OLE de IDRISI provee una amplia gama de funciones para controlar IDRISI, incluyendo la ejecución de módulos, la visualización de archivos y la manipulación de las variables ambientales de IDRISI. Con los ambientes de programación visual tales como Delphi, Visual C++ y Visual Basic, el acceso a estas funciones resulta muy fácil.

Desde el menú Modeling, se puede acceder a algunas instrucciones específicas y a un manual de referencia completo. Mientras que API brinda una amplia variedad de herramientas, la mayoría de los usuarios sólo necesitan unas pocas –generalmente la operación RunModule que puede ejecutar cualquier módulo, el operador Display File (para la construcción de producciones visualizadas automáticamente) y un par de procedimientos para acceder la estructura de la carpeta de proyectos.

También se proveen instrucciones en el archivo de ayuda de API (en el menú Modeling) para ver cómo se cambian los lenguajes para el sistema de menús de IDRISI para que Ud. pueda desarrollar aplicaciones e incorporarlas como extensiones directas al IDRISI mismo.



# CAPÍTULO 11 - Desarrollo de Bases de Datos

## Introducción

Como se ha ilustrado en el capítulo **Introducción a SIG**, la base de datos se encuentra en el centro del Sistema de Información Geográfica. De hecho, ésta provee del combustible al SIG. Las tareas de encontrar, crear, ensamblar e integrar estos datos pueden llamarse en forma colectiva *desarrollo de bases de datos*. A pesar de no ser la parte más interesante, el desarrollo de la base de datos puede fácilmente consumir entre el 80 y el 90 por ciento del tiempo y de los recursos dispuestos para cualquier proyecto. Este capítulo discute muchos de los temas relacionados con el desarrollo de bases de datos y además presenta un resumen de las herramientas del desarrollo de bases de datos incluidas en IDRISI. Además se presentan técnicas e ideas para importar datos raster, particularmente imágenes satelitales.

## Colectando Datos

El primer paso en el desarrollo de bases de datos es por lo general la identificación de las capas de datos necesarias para el proyecto. A pesar de ser tentador adquirir cada capa de datos disponible que coincida con el área de estudio, usualmente es más eficiente identificar lo que se necesita antes que aquello que está disponible. Esto ayuda a evitar los problemas de definiciones de proyectos dirigidas por datos y alienta un enfoque dirigido por preguntas.

Además de identificar los temas que son necesarios (Ej.: elevación, cobertura terrestre), también es importante determinar qué resolución (precisión) y qué nivel de exactitud se necesitan. Estos temas serán abordados en detalle más abajo.

Una vez que los requerimientos de datos necesarios para el proyecto han sido especificados, la búsqueda de datos puede comenzar. Existen cinco formas principales de incorporar datos en la base de datos:

1. Encontrar datos en formato digital e importarlos.
2. Encontrar datos en papel y digitalizarlos.
3. Recoger datos Ud. mismo en el campo, y luego ingresarlos.
4. Sustituir una capa de datos existente como un suplente.
5. Derivar datos nuevos a partir de datos existentes.

## Encontrar Datos en Formato Digital e Importarlos

### Dónde Encontrar Datos

En muchos países, algunas organizaciones gubernamentales proveen datos como un servicio más. En los Estados Unidos, estos datos a menudo son gratis para bajar por vía electrónica o están disponibles por una tarifa pequeña. El Servicio Geológico de los Estados Unidos (United States Geological Survey), la Administración Nacional de los Oceanos y la Atmósfera (National Oceanic and Atmospheric Administration) y la Oficina de Censos (Census Bureau) son buenos ejemplos de agencias gubernamentales en Estados Unidos que tienen orden de crear y proveer datos digitales. Todas estas agencias poseen sitios web que brindan información acerca de la disponibilidad de datos digitales.

Además, cada vez es más común que los estados (o provincias) tengan una agencia o departamento en particular responsable de crear, mantener y distribuir capas de datos SIG. En el estado de Massachusetts, por ejemplo, la oficina del estado MASSGIS tiene esta responsabilidad. Para muchos, Internet se está convirtiendo rápidamente en el método preferido para encontrar y adquirir datos suministrados por el gobierno.

Algunas compañías comerciales también ofrecen datos digitales. Estos datos pueden ser juegos genéricos de capas de base comúnmente usadas, como las redes de transporte, o pueden ser personalizados según las necesidades del usuario en particular. Las compañías comerciales a menudo comienzan con datos del gobierno obtenidos gratuitamente y le “agregan valor” al convertirlos a formatos de software específicos o al actualizarlos.

Con la proliferación de las tecnologías SIG y del procesamiento de imágenes, muchas instituciones no gubernamentales y académicas poseen capas de datos que le pueden ser útiles para su proyecto. Aunque estas organizaciones raras veces crean datos específicamente para compartir con otros, a menudo suelen poner a disposición lo que han recogido. Por lo tanto, generalmente es útil identificar otros investigadores o instituciones que

estén trabajando en la misma área de estudio para obtener información sobre sus datos. Los foros de discusiones electrónicas, como IDRISI-L, también brindan una posibilidad para solicitar capas de datos particulares. El sitio web de Clark Labs, [www.clarklabs.org](http://www.clarklabs.org), incluye una página de enlaces a distintos sitios relacionados con SIG y el procesamiento de imágenes, muchos de los cuales ofrecen datos.

Una vez que Ud. ha localizado datos electrónicos útiles para su proyecto, necesita importarlos al software que está usando. Suena simple. En teoría, estas conversiones de formatos son triviales. Pero en la práctica, es común encontrarse con el dilema de que llegar a lo que Ud. quiere con lo que Ud. tiene no es un proceso directo.

## Formatos Físicos

La información puede presentarse en CD-ROM, cinta de 8 mm, Zip o en cualquier otro formato físico menos común. Cuando se adquiere información, asegúrese de preguntar acerca del medio físico en el cual le será proporcionada y de tener las utilidades para leer ese tipo de medio. La habilidad para descargar grandes archivos de datos por vía electrónica ha disminuido este problema considerablemente. Sin embargo, aún con las descargas por medio de la red, el acceso al software apropiado y a la red, tal como un cliente FTP, es necesario.

## Formato de los Datos

Ud. también debe determinar el formato de los archivos de datos. En términos generales, a qué categoría pertenece cada archivo. Por ejemplo, una capa de datos de sitios de pozos podría guardarse como un archivo de datos raster, vectorial, de base de datos o de hoja de cálculo. Más en detalle, Ud. deberá saber si el archivo se encuentra en algún formato de software en particular, un formato de agencia o algún tipo de formato de intercambio de datos. IDRISI hace posible la importación directa de un número de formatos de datos estándar raster, vectoriales y de atributo.

Aún si el formato de archivo en particular que Ud. posee no está directamente avalado por las rutinas de importación de IDRISI, Ud. podrá usarlo igualmente. Los datos raster suelen tener una estructura más simple que los datos vectoriales. A menudo se da el caso en donde se puede importar un archivo raster al IDRISI usando una herramienta de un nivel bajo, como por ejemplo el GENERICRASTER para ordenar los píxeles. Los datos vectoriales son más complejos, y a menos que la estructura sea extremadamente simple, hay pocas probabilidades de que pueda importar datos vectoriales usando herramientas de nivel bajo.

Para datos tanto raster como vectoriales, los software de traducción pueden brindar el puente entre el formato de datos actual y IDRISI. Los software de traducción para formatos de archivos SIG varían en el número de formatos que avalan y en precio. Su objetivo al usar un software de traducción es convertir el archivo que Ud. tiene para que se pueda importar desde IDRISI.

Cuando adquiere datos, también debe tener en cuenta la compresión de los datos. La compresión permite almacenar los archivos usando menos memoria de la que normalmente requieren. Hay dos tipos de compresión que debe tener en cuenta. La primera es usada por el mismo software SIG. IDRISI, por ejemplo, tiene un tipo de archivo binario empaquetado codificado *run-length*. Mientras que IDRISI puede usar estos archivos analíticamente, otros software SIG no tienen la capacidad de usarlos. Es mejor evitar compartir archivos que están comprimidos con rutinas de software específicos entre sistemas SIG diferentes.

El segundo tipo de compresión, a veces llamada “zipping”, se usa para archivos que no están en uso. Esta compresión se usa para hacer más fácil la transferencia y el almacenamiento de archivos. Los archivos deben ser descomprimidos o “unzipped” antes de ser usados.

Siempre pregunte acerca del software de compresión usado. Si Ud. no posee el mismo software, adquiera el archivo en un formato descomprimido o como un archivo ejecutable auto-extraíble (archivo comprimido que se descomprime sin necesidad de tener un software de compresión instalado en su computadora).

En el Sistema de Ayuda on-line de IDRISI hay información disponible sobre la importación de formatos de archivos específicos.

## Cómo Encontrar Datos en Papel y Digitalizarlos

Si los datos que necesita se encuentran en papel, deberá digitalizarlos (es decir, hacerlos digitales) para introducirlos en su base de datos SIG. Algunos datos de papel pueden ser digitalizados simplemente tipeándolos en un editor ASCII o en una tabla de base de datos. Por ejemplo, Ud. puede tener notas de campo tabulares tomadas de zonas de relevamiento de muestras que se pueden tipear directamente en el Taller para Bases de Datos (Database Workshop).

Con más frecuencia, los datos de papel se encuentran en forma de un mapa, una ortofoto o una fotografía aérea. Si desea extraer características particulares de un mapa, tales como contornos de elevación, zonas de vertientes o

límites de parques, entonces deberá digitalizarlas como características vectoriales usando una plaqueta digitalizadora.

(Alternativamente, las características visibles a simple vista de una ortofoto pueden capturarse con una digitalización en pantalla, tema que se discute más adelante).

Una plaqueta digitalizadora (o tabla digitalizadora) contiene una fina red de alambres que definen un sistema cartesiano de coordenadas para la plaqueta. La mayoría de las plaquetas tienen 1000 alambres por pulgada, lo que resulta en una resolución máxima de 1/1000 pulgada. El usuario adjunta el mapa en formato de papel a la plaqueta digitalizadora, luego busca características en el mapa con una púa digitalizadora (dispositivo similar al mouse) o una aguja (dispositivo similar a una lapicera). La plaqueta digitalizadora percibe las posiciones x y de la púa mientras las características son rastreadas y las comunica al software digitalizador.

Los paquetes de software digitalizadores varían en gran medida en la facilidad de uso y sus capacidades. CartaLinx, también un producto de Clark Labs, combina una interfase de usuario fácil con una edición digitalizadora y post digitalizadora flexible, y está recomendado para usarse con IDRISI.

La mayoría de los software digitalizadores le permiten al usuario “registrar” el mapa sobre la plaqueta digitalizadora. Este proceso establece la relación entre las coordenadas cartesianas de la plaqueta y el sistema de coordenadas del mapa de papel. El software compara las coordenadas de la plaqueta con las coordenadas del mapa para una serie de puntos de control, y luego deriva una función de ajuste de la mejor traducción. Esta función luego se aplica a todas las coordenadas enviadas desde la plaqueta hacia el software. Si su software digitalizador no ofrece esta traducción, puede usarse el módulo RESAMPLE de IDRISI para transformar las coordenadas de la plaqueta a coordenadas cartográficas luego de la digitalización.

Además de la digitalización por medio de plaquetas digitalizadoras, se pueden usar escáners para digitalizar imágenes en papel, como mapas o fotos aéreas. A diferencia de las plaquetas digitalizadoras que producen datos vectoriales, los escáners producen datos raster. Además, los escáners no capturan características diferentes sino que miden la reflectancia relativa de la luz reflejada por un documento gráfico de acuerdo con una resolución definida por el usuario, usualmente especificada en puntos por pulgada. Cada punto se convierte en un pixel en la imagen resultante. Los sensores detectan los reflejos del rojo, verde y azul (o escala de grises), y los almacenan como valores digitales para cada pixel. La imagen escaneada luego es importada al software SIG como una imagen raster. Las imágenes escaneadas normalmente son importadas al IDRISI por medio de los formatos de archivo .BMP o .TIF.

Una vez escaneadas las características, como por ejemplo los caminos, pueden extraerse y colocarse en un formato de archivo vectorial usando un software especializado. No obstante, este proceso es a menudo muy costoso y poco exacto, y requiere fuentes de papel muy limpias para el escaneo. Otro método para extraer características vectoriales de imágenes raster escaneadas es la digitalización en pantalla.

Con la digitalización en pantalla, a veces llamada digitalización “heads-up”, el mapa o foto escaneado es visualizado en la pantalla y las características son digitalizadas utilizando un mouse común. El módulo RESAMPLE puede usarse para georegistrar la imagen antes de la digitalización. Tanto IDRISI como CartaLinx permiten capturar características en forma de archivos vectoriales de una imagen raster visualizada por medio de la digitalización en pantalla.

## **Cómo Recoger Datos de Campo Usted Mismo y Luego Ingresarlos**

Para muchos proyectos de investigación, es necesario ir al campo mismo y recoger datos. Cuando se recogen datos en el campo para usarlos en un SIG, es imperativo conocer la ubicación del punto de cada dato recogido. Dependiendo de la naturaleza del proyecto y del nivel de exactitud requerido, los mapas en papel pueden usarse conjuntamente con marcas físicas de reconocimiento (Ej.: caminos y edificios) para determinar ciertas ubicaciones. Sin embargo, para muchos proyectos, se necesitan instrumentos tradicionales de reconocimiento o dispositivos del Sistema de Posicionamiento Global (GPS) para localizar con exactitud los puntos de los datos.

Las coordenadas de localización de los relevamientos tradicionales son generalmente procesadas en un software de Geometría de Coordenadas (COGO) y luego pueden ser transformadas en un tipo de archivo vectorial compatible con SIG. CartaLinx puede realizar esta transformación.

No obstante, para muchas aplicaciones de SIG, los dispositivos GPS pueden representar una alternativa más económica. El Sistema de Posicionamiento Global está compuesto por 274 satélites del Departamento de Defensa de los Estados Unidos que tienen su órbita alrededor de la Tierra a unos 20.000 kilómetros aproximadamente. Cada satélite transmite continuamente señales de tiempo y lugar. Un receptor GPS procesa las señales del satélite y calcula su posición.<sup>46</sup> El nivel de error de la posición depende de la calidad (y el precio) del receptor, de las

---

<sup>46</sup> Muchas compañías de GPS (Ej.: Trimble, Magellan) poseen excelentes sitios web que explican cómo son calculadas las

condiciones atmosféricas y de otras variables. Algunas unidades sólo ofrecen la visualización de los lugares, otras en cambio, almacenan en forma electrónica la información de posicionamiento para poder luego cargarla en una computadora.

IDRISI incluye un link GPS. Cuando éste se encuentra activo, la posición grabada por el receptor GPS se muestra en la ventana de visualización activa, y se actualiza a medida que cambia la posición. Las coordenadas geodésicas producidas por el receptor son automáticamente proyectadas al sistema de referencia de la visualización. Este link GPS está provisto específicamente para visualizar y almacenar puntos de parada y caminos. CartaLinx también incluye un link GPS, y permite más flexibilidad en la creación de capas de datos a partir de los datos del GPS.

La mayoría de los software de procesamiento de datos GPS aceptan varios formatos de exportación SIG. Los archivos de forma (shape) y los archivos DXF son generalmente usados como un puente hacia IDRISI. Si esos formatos no están disponibles o si el grupo de datos es lo suficientemente pequeño para ser ingresado a mano, la creación de un archivo vectorial IDRISI se logra fácilmente a través del uso de un editor de texto como el módulo Edit de IDRISI.

Adicionalmente, el software GPS comúnmente exporta a varios tipos de archivos de texto ASCII. El módulo XYZIDRIS de IDRISI importa uno de los tipos más comunes. La entrada para XYZIDRIS debe ser un archivo ASCII delimitado por espacio o coma, en el cual los valores numéricos X, Y y Z (donde Z = elevación o un identificador numérico) están separados por uno o más espacios y cada línea termina con un par CR/LF. El XYZIDRIS produce un archivo vectorial de puntos IDRISI.

## Cómo Sustituir una Capa de Datos Existente por un Suplente

Algunas veces, simplemente no hay forma alguna de encontrar o crear una capa de datos particular. En estos casos, es posible sustituir datos existentes por un sustituto. Por ejemplo, supongamos que un análisis requiere información de la ubicación de las líneas eléctricas, pero no hay disponible ningún archivo de datos de líneas eléctricas y Ud. no tiene tiempo o fondos para recoger los datos en el campo. Sin embargo, Ud. sabe que en su área de estudio las líneas eléctricas generalmente se encuentran al costado de los caminos pavimentados. Para los propósitos de su análisis, si el nivel de error potencial introducido es aceptable, puede usar una capa de caminos pavimentados como un sustituto para las líneas eléctricas.

## Cómo Derivar Datos Nuevos a partir de Datos Existentes

Las capas de datos nuevas también pueden ser derivadas a partir de datos existentes. Esto se conoce como mapeo derivativo y es la principal forma en la cual crece una base de datos SIG. Con el mapeo derivativo, se combinan algunos conocimientos de relaciones con capas de datos existentes para crear nuevas capas de datos. Por ejemplo, si se necesita una imagen de pendientes pero no existe ninguna, Ud. puede derivar la imagen de pendientes (usando el módulo SURFACE de IDRISI) a partir de un modelo de elevación digital, si éste se encuentra disponible. De manera similar, si necesita una imagen de la cantidad relativa de biomasa verde sobre el suelo, puede derivar dicha imagen de las bandas rojas e infrarrojas de imágenes satelitales.

Otra forma común de mapeo derivativo es la interpolación de una superficie raster (Ej.: un modelo de elevación o una superficie de temperatura) de una serie de puntos discontinuos o isolíneas usando la modelación TIN o Geostatísticas, ambos disponibles en IDRISI. Vea el capítulo **Interpolación de Superficies** para conseguir más información sobre esta forma de mapeo derivativo.

## Consideraciones

### Resolución

En todas las tareas de desarrollo de bases de datos hay varios puntos a considerar, sin importar la fuente de los datos. La primera consideración es la resolución de los datos. ¿Qué nivel de definición de detalles necesita Ud.? La resolución afecta el almacenamiento y el tiempo de procesamiento si es muy alta, y limita las preguntas que Ud. puede realizar si es muy baja.

La resolución puede referirse a los componentes espaciales, temporales o de atributos de la base de datos. La resolución espacial se refiere al tamaño del pixel en los datos raster o a la escala del mapa que ha sido digitalizado

---

posiciones a partir de las señales satelitales.

para producir datos vectoriales. La resolución temporal se refiere a la periodicidad de los datos y a la posibilidad de que las imágenes en las series de tiempo sean suficientemente frecuentes y estén espaciadas adecuadamente. La resolución de atributos se refiere al nivel de detalles capturado por los valores de los datos. Esto puede

ejemplificarse por la diferencia entre un mapa de cobertura terrestre con una sola clase de bosque, un mapa de cobertura terrestre con clases de bosques de madera dura y blanda y un mapa de cobertura terrestre con muchas clases de bosques diferentes.

## Exactitud

La exactitud es la segunda consideración. Además de tener relación con la resolución, la exactitud también es una función de los métodos y el cuidado con los cuales se recogieron y digitalizaron los datos. Desafortunadamente, no siempre es fácil evaluar la exactitud de las capas de datos. No obstante, la mayoría de las agencias gubernamentales de mapeo poseen estándar de mapeo disponibles. La estructura de archivo metadato (documentación) de IDRISI incluye campos para la información de exactitud, sin embargo muchos otros formatos de archivo no llevan información de exactitud. Además, aún cuando se comunica dicha información, el uso inteligente de la información de exactitud en el análisis SIG es todavía un camino para la investigación activa. Las capacidades de IDRISI en esta área se discuten en el capítulo **Apoyo en la Toma de Decisiones**.

## Georeferenciamiento

La tercera consideración es el georeferenciamiento. Las capas de datos de varias fuentes a menudo están georeferenciadas usando diferentes sistemas de referencia.<sup>47</sup> Para la visualización y el análisis SIG, todas las capas de datos que van a ser utilizadas juntas deben usar el mismo sistema de referencia. En el caso de que se conozcan los detalles de los sistemas de referencia, éstos se pueden convertir usualmente con el módulo PROJECT de IDRISI.

Sin embargo, es posible descargar archivos gráficos de la Red, por ejemplo, que no estén georeferenciados. A pesar de que IDRISI acepta muchas proyecciones, Ud. puede encontrar datos en una proyección no aceptada. En ambos casos, no podrá usar el PROJECT. A veces es posible georeferenciar un archivo no referenciado o un archivo con una proyección no aceptada por medio del remuestreo (el módulo RESAMPLE de IDRISI) si los puntos de las ubicaciones conocidas pueden encontrarse en la imagen no referenciada. Se recomienda leer el capítulo **Georeferenciamiento** para obtener más información acerca de este tema clave. Además, vea la sección sobre la Integración de Datos desarrollada más adelante.

## Costo

Finalmente, la cuarta consideración en el desarrollo de bases de datos es el costo. Este debe evaluarse en términos tanto de tiempo como de dinero. Otras consideraciones incluyen la posibilidad de que los datos se usen una sola vez o varias veces, el nivel de exactitud necesario para los usos particulares (y futuros) de los datos y la frecuencia con la que se debe actualizar una base de datos para que siga siendo útil.

# Instrucciones Generales de Importación

IDRISI necesita archivos en formato Intel. Por lo general, esto sólo ocasiona problemas cuando los datos enteros son adquiridos de Macintosh, UNIX, estaciones de trabajo y plataformas que usan formato Motorola. El orden de los bytes es diferente en los dos formatos. El módulo GENERICRSTER se puede usar para revertir el orden de los bytes de un archivo entero.

Si importa datos de ciertos medios, los archivos se escribirán en su disco duro con un atributo de sólo lectura. Esto se puede cambiar con el Explorador de Windows en el diálogo Propiedades de cada archivo.

## Herramientas para la Importación

Los archivos a veces se encuentran en un formato no especificado. Los siguientes módulos son útiles para inspeccionar archivos y cambiar las estructuras de los mismos.

Edit: Muestra y edita un archivo ASCII. Los datos vectoriales son a menudo ASCII.

CONVERT: convierte archivos ASCII raster y vectoriales o archivos binarios.

---

<sup>47</sup> Un sistema de referencia está definido por un sistema de proyección, datos y grillas. Para más información, vea el capítulo **Georeferenciamiento**.

**VIEW STRUCTURE** del Explorador de Archivos de IDRISI: Muestra los contenidos de nivel byte de cualquier archivo (en formato ASCII o binario). Se utiliza para visualizar archivos de datos con el objetivo de detectar la presencia o el tamaño del encabezamiento, y también retornos de carro/barras espaciadoras (CR's) y líneas de alimentación (LF's).

**CRLF**: Agrega o elimina retornos de carro/barras espaciadoras y líneas de alimentación. Se usa con módulos de importación que requieren longitudes específicas de registro fijo (Ej.: DLG's, DEM's).

**VAR2FIX**: Convierte archivos ASCII de longitud variable a longitud fija. Se usa conjuntamente con CRLF.

**Metadata**: Crea y actualiza archivos de documentación para archivos de datos que ya se encuentran en formato IDRISI.

**GENERICRASTER**: Importa, convierte y cambia el orden de los bytes en datos de una banda o de bandas múltiples en formato banda intercalada por línea (BIL), banda intercalada por pixel (BIP) o bandas secuenciales (BSQ).

**SSTIDRIS**: Convierte imágenes raster ingresadas desde un programa de hoja de cálculo o de cualquier formato de grilla ASCII en una imagen IDRISI.

## Importando Imágenes Satelitales

IDRISI incluye varias rutinas especiales de importación para formatos específicos de imágenes satelitales, tales como LANDSAT, HDF-EOS y SPOT. Si una rutina de importación específica no se encuentra disponible para el formato de sus datos, se pueden usar las herramientas genéricas de importación de IDRISI para traer las imágenes satelitales al mismo. Existen tres puntos a tomar en cuenta cuando se intenta importar datos satelitales usando las herramientas genéricas: la ubicación y los contenidos de la información del encabezamiento (información que describe los datos), el tamaño en bytes de los datos y el formato en el que están almacenados los mismos.

La primera tarea es localizar y leer la información del encabezamiento. Por lo general, el encabezamiento se almacena como un archivo separado en formato ASCII, o se distribuye como documentación en papel. Use el módulo EDIT para leer estos datos. Si, como una tercera posibilidad, el encabezamiento se adjunta al archivo de datos, éste se almacena en formato binario porque las imágenes satelitales usualmente son distribuidas en ese formato. En este caso, Ud. Puede intentar leer la información desde el encabezamiento con la utilidad VIEW STRUCTURE del Explorador de Archivos de IDRISI que muestra los datos binarios como textos ASCII. Si conoce el número de filas y columnas de la imagen, pero no el tamaño del encabezamiento, existe una forma de averiguarlo. Si la imagen está en formato binario byte, el número de bytes de la imagen debe ser igual al número de pixeles. Para averiguar el número de pixeles de la imagen, multiplique el número de filas por el número de columnas. Los bytes extra en el archivo de datos deben tener el tamaño del encabezamiento. Si el archivo contiene datos enteros de 2 bytes, el número de bytes en la imagen es igual a las filas multiplicadas por las columnas multiplicadas por 2. Se puede determinar el tamaño exacto de un archivo usando el comando Propiedades en el Explorador de Windows. Por ejemplo, si una imagen tiene 512 filas y 512 columnas, y el tipo de datos es binario, el tamaño del archivo sin el encabezador debe ser de 262.144. Otro ejemplo: si sabemos que el archivo tiene 512 filas y 512 columnas y el tamaño del archivo es 262.656, podemos asumir que el tamaño del encabezamiento es de 512 bytes.

Los contenidos de la información del encabezamiento se presentan en diversos formatos y con niveles de detalles variables. Esta sección le aconsejará qué buscar en él, pero no puede anticipar el formato en el cual Ud. encontrará esa información.

Hay tres fragmentos de información que debe encontrar en el encabezamiento (las respuestas a 1 y 2 determinarán la rutina de importación que Ud. va a usar):

1. el formato del archivo de datos;
2. si hay un archivo del encabezamiento adjuntado al archivo de datos, y su tamaño; y
3. el número de filas y columnas en el archivo de datos.

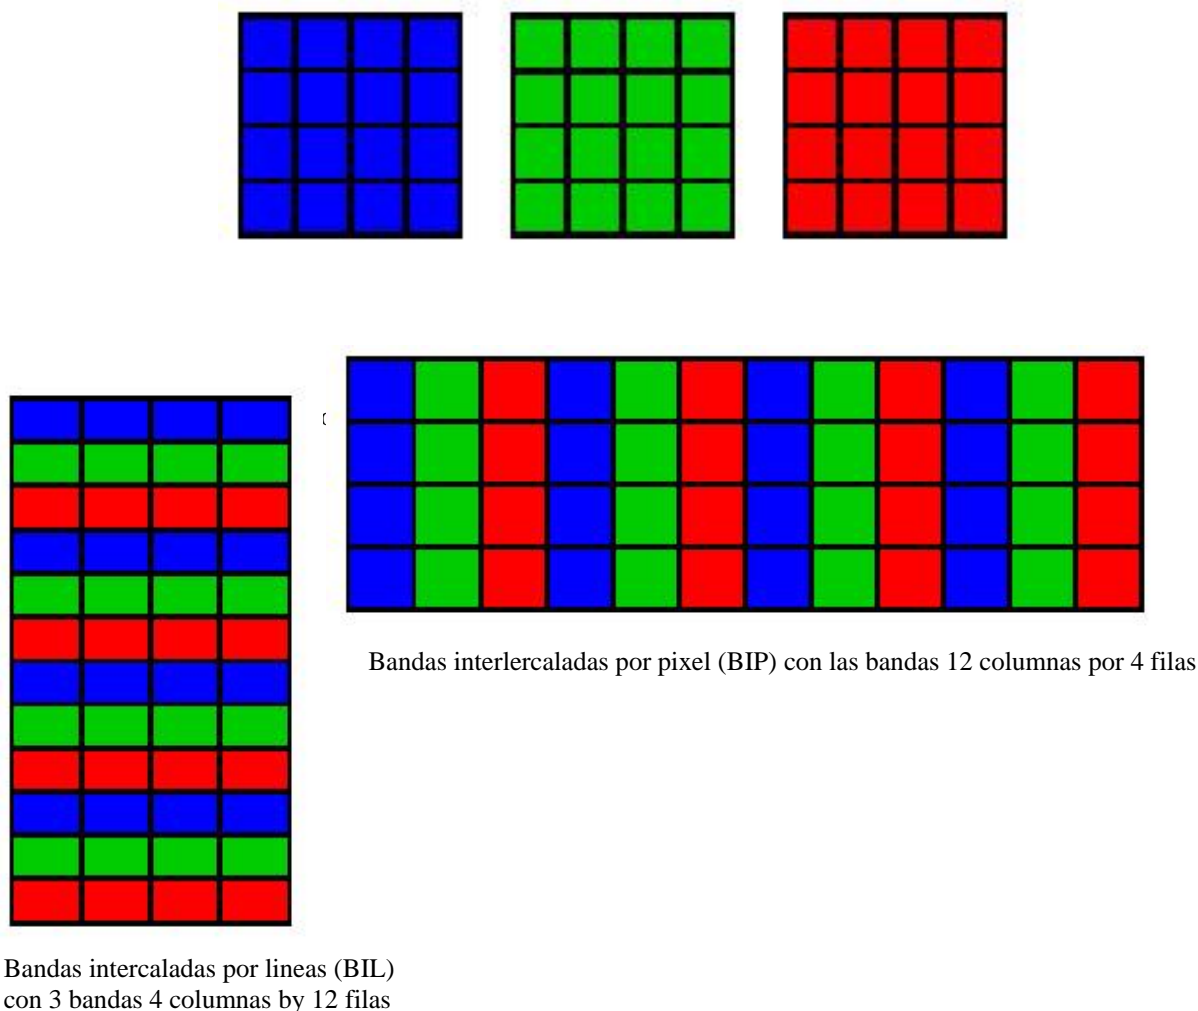
La mayoría de las imágenes satelitales son distribuidas en uno de dos formatos de archivo: bandas secuenciales (BSQ) y banda intercalada por línea (BIL). El formato de bandas secuenciales es igual al formato de imagen de IDRISI. Los valores de los datos son almacenados como una sola serie de números y cada banda de las imágenes se encuentra en un archivo de datos separado. Las imágenes satelitales pancromáticas<sup>48</sup> del SPOT y las TM y MSS

---

<sup>48</sup> La documentación para la banda pancromática del SPOT indica que se encuentra en formato BIL, pero solo contiene una banda, entonces no hay intercalado. Esto mismo ocurre con el formato BSQ.

del LANDSAT son comúnmente distribuidas en este formato. El formato de banda intercalada por línea (BIL) almacena todas las bandas de imágenes multispectrales en un solo archivo de datos. Las bandas son combinadas guardando la primera fila de datos de la primera banda de imagen, seguida por la primera fila de datos de la segunda banda, y así sucesivamente por cada banda de imagen almacenada en el archivo de datos. El archivo de datos luego continúa con la segunda fila de datos de la primera banda, la segunda fila de datos de la segunda banda, y así sucesivamente. Las imágenes multispectrales SPOT (SPOT-XS) son generalmente distribuidas en formato BIL. Un tercer formato, banda intercalada por pixel (BIP), es poco común pero se usa con datos más antiguos. Las siguientes figuras ilustran los tres formatos.

#### Formatos de Imágenes Satelitales



**Figura 11-1**

Con los archivos de formato BSQ, se usan las dos siguientes rutinas de importación:

1. Si hay un encabezamiento adjuntado al archivo de datos, use el módulo GENERICRASTER y luego especifique BSQ sin ningún encabezador. El GENERICRASTER eliminará el encabezador, le dará un nuevo nombre con extensión .RST al archivo de datos y creará un archivo de documentación. El GENERICRASTER preguntará por el número de filas y columnas, información mínima necesaria para crear el archivo de documentación. El GENERICRASTER también preguntará por información adicional, como los parámetros del sistema de referencia que Ud. debería encontrar en el encabezador. Cuando tenga dudas, puede probar con los siguientes valores: Mínimo X=0, Máximo X=1 (o cantidad de columnas), Mínimo Y=0, Máximo Y=1 (o cantidad de filas), Sistema de Referencia=Plano.
2. Si el archivo del encabezamiento está separado del archivo de datos, entonces sólo necesita cambiarle el nombre al archivo de datos para ponerle una extensión .RST (con el comando Cambiar nombre del Explorador de Windows).

Luego ejecute el Metadata desde el menú File para crear el archivo de documentación. Aquí también debe saber el número de columnas y filas para poder completar el archivo de documentación, pero además debe ingresar toda la información del sistema de referencia disponible en el encabezador. Si desconoce los valores, pruebe ingresar los valores detallados en el párrafo anterior, más los valores Unidades del Sistema de Referencia=M y Unidad de Distancia=1.

Para todos los archivos BIL, con o sin un encabezador, se usa la siguiente rutina de importación:


Si hay un encabezamiento adjuntado, determine su tamaño (en bytes) y luego use el módulo GENERICRASTER. El GENERICRASTER separará y creará archivos individuales de imagen y de documentación con formato IDRISI para cada banda de imagen.

Hay algunos errores comunes durante el proceso de importación que pueden darle al usuario información útil para la corrección. Si el tamaño del encabezamiento se especifica erróneamente usando el GENERICRASTER, la imagen no será importada correctamente. Debido a que se extrae demasiado o muy poco del archivo como un encabezador, los datos reales resignados están incompletos o bien contienen información extra. Esto puede conducir a un mensaje de error que le informa que la imagen tiene un tamaño incorrecto o que ésta se visualizará con inexactitud. (Ej.: los datos del lado derecho pueden aparecer movidos al lado izquierdo). Necesitará determinar el tamaño correcto del encabezamiento y tratar nuevamente.

Si una imagen se ha importado exitosamente pero la visualización de la misma está movida o distorsionada hacia un lado, es posible que haya especificado incorrectamente el número de filas y columnas en el archivo de documentación. Vuelva a verificar su archivo de documentación para corregir la información o utilice el método abordado anteriormente para determinar las filas y columnas correctas basándose en el tamaño de la imagen y del encabezador. Si una imagen se ha importado exitosamente pero la visualización de la misma tiene un efecto de rayado, existen dos posibles causas. Si el rayado es vertical, pruebe importar la imagen como un archivo con formato BIP a través del GENERICRASTER. Si el rayado es horizontal, pruebe importar la imagen como un archivo con formato BIL. La primera imagen de la izquierda más abajo ilustra una importación con un número incorrecto de bandas con un tipo importación BIL. La imagen del centro muestra un resultado típico cuando no se calcula correctamente el encabezador. La imagen de la derecha demuestra el resultado de los casos en que se especifica erróneamente el número de columnas.

Un error típico asociado con la importación de datos enteros resulta de datos que se originaron en un entorno UNIX. Si luego de haber importado exitosamente datos enteros, el resultado muestra valores exageradamente máximos y mínimos en la imagen, seguramente se deben cambiar de lugar los bytes. Ejecute una vez más la rutina del GENERICRASTER y pruebe con la opción Swap byte order (cambiar el orden de los bytes). Esta opción se usa para convertir archivos UNIX y Macintosh que tienen el orden de byte bajo / byte alto revertido con respecto a los sistemas basados en Intel.

Errores comunes durante la importación



**Figura 11-2**

## **Importando Datos SIG**

Gran parte de la información presentada anteriormente sobre la importación de imágenes satelitales también es válida para la importación de datos raster SIG. IDRISI ofrece rutinas determinadas de importación para muchos formatos comunes SIG de agencia y de software específicos. Los procedimientos para importar formatos comunes de datos SIG se pueden encontrar en el Sistema de Ayuda on-line. Busque el nombre del formato que desea importar en el índice del Sistema de Ayuda. En muchos casos, los datos SIG pueden almacenarse en un formato que se puede importar al IDRISI, tales como los archivos ERDAS Imagine, ESRI ArcRaster, GEOTIFF o GRASS.



# Integración de los Datos

## Requerimientos para la Integración de los Datos

La integración de los datos se refiere al uso de diversas capas de datos juntas en la visualización o en el análisis. Hay muchos parámetros que deben coincidir si varias capas de datos se van a usar conjuntamente. Primero, deben coincidir los sistemas de referencia.<sup>49</sup> Esto es importante ya que a menudo combinamos temas separados basándonos en sus características espaciales. Una capa vectorial de caminos puede superponerse adecuadamente sobre una imagen satelital raster, por ejemplo, sólo si ambas capas poseen el mismo sistema de referencia. Un par de coordenadas x, y particular en el archivo vectorial debe representar exactamente el mismo lugar sobre el terreno de ese mismo par de coordenadas x, y en la imagen raster.

Para poder usar capas raster en operaciones entre imágenes, como OVERLAY, deben coincidir el tamaño de las imágenes, el número de filas y columnas y la resolución de píxeles de las mismas. Tenga en cuenta que si dos de estas tres condiciones se cumplen, la tercera se da automáticamente.

Los pasos usados para integrar capas de datos, especialmente si los datos están transformados, deben almacenarse en el campo Lineage del archivo de documentación de cada capa de datos. Por ejemplo, es superfluo hacer píxeles pequeños de píxeles más grandes, y esto a menudo se hace para lograr la integración de datos. Sin embargo, es importante saber que la información contenida en esos píxeles más pequeños todavía representa datos recogidos en una resolución más gruesa. Dicha información debe ser almacenada en el archivo de documentación de la nueva imagen para que los usuarios sepan que la resolución aparente excede la resolución de la información.

## Herramientas para la Integración de Datos

Los módulos PROJECT y RESAMPLE son las herramientas principales disponibles en IDRISI para georeferenciar y cambiar sistemas de referencia. El capítulo **Georeferenciamiento** detalla las diferencias entre estos dos módulos e indica cuándo deben emplearse. Además, el **Tutorial** incluye ejercicios sobre el uso de PROJECT y RESAMPLE.

El módulo WINDOW se usa para cambiar los límites de imágenes raster. Funciona guardando un subgrupo de imágenes más chicas como una nueva imagen.

Los cambios del número de filas y columnas y/o de la resolución de píxeles en una imagen se pueden lograr con los módulos CONTRACT, EXPAND y PROJECT. CONTRACT y EXPAND funcionan disminuyendo o duplicando los píxeles de una imagen por un múltiplo entero. Por ejemplo, una imagen con 100 filas y 100 columnas y con una resolución de píxeles de 30 metros puede contraerse a una imagen de 25 filas y 25 columnas usando un factor de contracción de 4. De manera similar, una imagen con 100 filas y 100 columnas se puede transformar en una imagen de 1000 filas y 1000 columnas usando EXPAND y un factor de expansión de 10.

CONTRACT y EXPAND no pueden usarse para contraer o expandir una imagen por un factor no entero (Ej.: 1,5). En estos casos, el método más fácil de usar es PROJECT. Proyecte el mismo sistema de referencia en el que se encuentra actualmente el archivo, ingrese el nuevo número de filas y columnas y elija la técnica de remuestreo que más se ajuste a sus datos y a sus aplicaciones. Generalmente, si se usan datos cuantitativos, debe elegirse el tipo de remuestreo bilineal; pero si se usan datos cualitativos, debe elegirse el remuestreo de tipo vecino más próximo.

## Conclusiones

El desarrollo de bases de datos no suele ser rápido ni fácil. La calidad de la base de datos, en muchos casos, limita la calidad de cualquier análisis resultante que se lleve a cabo con los datos. Existe un número significativo de trabas técnicas que aparecen usualmente durante el desarrollo de las bases de datos y que hacen que el usuario se rinda fácilmente ante las mismas. Sin embargo, a pesar de estas dificultades, es importante mantener un enfoque dirigido hacia el proyecto en el análisis SIG y también limitar la influencia que pueden tener las restricciones de los datos en la definición de los problemas a tratar.

---

<sup>49</sup> La proyección, los datos y la grilla del sistema de referencia deben coincidir para que el sistema de referencia coincida

# CAPÍTULO 12 - Georeferenciamiento

El Georeferenciamiento se refiere a la forma en la que las ubicaciones en los mapas se relacionan con las ubicaciones en la superficie de la tierra. El Georeferenciamiento requiere diversos ingredientes:

- Una lógica para referirse a las ubicaciones sobre la superficie terrestre – un tema del campo de la Geodesia;
- Una implementación específica de esa lógica, conocida como Datos Geodésicos - un tema del campo de Relevamientos;
- Una lógica para hacer corresponder las ubicaciones a sus posiciones gráficas - un tema del campo de la Cartografía; y
- Una implementación de esa lógica, conocida como Estructura de los Datos - un tema de los software SIG y de Mapeo de Escritorio, y en este caso, de IDRISI.

## Geodesia

La Geodesia es el campo de estudios que se ocupa de la medición del tamaño y forma de la tierra y de las posiciones sobre ésta. El problema más importante que enfrentan los Geodestas es el hecho de que la superficie de la tierra tiene forma irregular. Por ejemplo, imagine dos lugares (A y B) en cualquiera de los extremos de una larga y delgada playa bordeada por acantilados profundos (Figura 13-1). Evidentemente la distancia que uno puede determinar entre los dos lugares depende de la ruta elegida para tomar la medida. La distancia medida a lo largo del acantilado va a ser más larga que la medida a lo largo de la costa. Entonces, las irregularidades (colinas y valles) a lo largo de la superficie a medirse pueden generar ambigüedades en la distancia (y por consiguiente en la ubicación). Para mejorar esta situación, es una práctica común reducir todas las medidas a una superficie de medida más regular – una *superficie de referencia*.




Figura 13-1

## Geoide

La superficie de referencia más antigua se conoce como *geoide*. El geoide puede pensarse como el nivel medio del mar, o el supuesto caso donde estaría el nivel medio del mar, si éste pudiera fluir bajo los continentes. En términos más técnicos, el geoide es una *superficie equipotencial de gravedad* que define todos los puntos en los cuales la fuerza de gravedad es equivalente a la experimentada en la superficie del océano. Debido a que la tierra gira sobre su eje y hace que la gravedad sea contrarrestada por la fuerza centrífuga en forma progresiva hacia el Ecuador, uno espera que la forma del geoide sea una esfera ovalada – un objeto en forma de esfera ensanchada en la parte media y achatada en los polos. En otras palabras, el geoide tiene la naturaleza de una elipse de revolución – un *elipsoide*.

Como una superficie de referencia, el geoide posee varias ventajas – tiene una interpretación física simple (y una posición observable a lo largo de la costa), y define el horizonte para la mayoría de los instrumentos tradicionales de medición. Entonces, por ejemplo, nivelar un teodolito o sextante es, por definición, el proceso de referir el instrumento al geoide.

## Elipsoides de Referencia

Desafortunadamente, el geoide mismo resulta algo irregular. Debido a amplias diferencias en los materiales de la tierra (como por ejemplo, materiales más pesados del lecho del océano y materiales más livianos del continente, o distribuciones irregulares como montañas y los desequilibrios isostáticos), el geoide contiene ondulaciones que también introducen ambigüedades de distancia y posición. Como resultado, se ha vuelto una práctica muy común de los estudios geodésicos modernos usar superficies de referencia abstractas que constituyen aproximaciones cercanas a la superficie del geoide y que además proveen elipsoides de referencia perfectamente suaves (Figura 13-2). Al elegir una que es tan aproximada como sea posible, la diferencia entre el nivel de un instrumento de medición (definido por el geoide irregular) y el horizontal del elipsoide de referencia es minimizada. Más aún, al reducir todas las medidas a esta forma idealizada, las ambigüedades de distancia (y posición) son eliminadas.




Figura 13-2

Existen muchos elipsoides diferentes en el uso geodésico (ver **Apéndice 1: Parámetros del Elipsoide**). Éstos pueden ser definidos por la longitud de los semi-ejes<sup>50</sup> mayor (a) y menor (b) (Figura 13-3), o por la longitud del semi-eje mayor junto con el grado de aplanamiento [ $f = (a-b) / a$ ]. La razón de tener tantos elipsoides diferentes es que éstos, al ser diferentes, otorgan mejores concordancias con la forma del geoide en diferentes posiciones. El elipsoide elegido para usar es aquél que mejor coincide con el geoide para la posición particular de interés.




Figura 13-3

## Datums Geodésicos

Al seleccionar un elipsoide de referencia específico para usar en un área específica y orientarlo al paisaje, se define lo que se conoce en Geodesia como un *datum*. Un *datum* entonces, define un elipsoide (y éste está definido por los semi-ejes mayor y menor), una posición inicial, un acimut inicial (una dirección de referencia para definir la dirección del Norte) y la distancia entre el geoide y el elipsoide en la posición inicial. La tarea de establecer un *datum* le pertenece a los investigadores geodésicos, y se realiza en el contexto de la constitución de redes nacionales o internacionales de investigación de control geodésico. Un *datum* está diseñado para establecer una superficie de referencia permanente, aunque recientes avances en la tecnología de investigación han llevado a muchas naciones a redefinir sus datos actuales.

La mayoría de los *datums* sólo intentan describir una porción limitada de la tierra (usualmente a una escala nacional o continental). Por ejemplo, el *datum* Norteamericano (NAD) y el *datum* Europeo describen grandes porciones de la tierra, mientras que el *datum* Kandawala se usan para Sri Lanka solamente. Todos estos *datums* se llaman *datums* locales ya que no intentan describir la tierra entera. En contraste, ahora estamos viendo el surgimiento de los Sistemas Geodésicos Mundiales (como el WGS84) que sí intentan brindar una sola y suave superficie de referencia para toda la tierra. Dichos sistemas son particularmente apropiados para medir sistemas que no utilizan la gravedad como marco de referencia, como los Sistemas de Posicionamiento Global (GPS). Sin embargo, en la actualidad no se los toma comúnmente como una base para el mapeo. Generalmente, uno busca *datums* locales, cientos de los cuales se encuentran en uso en la actualidad.

<sup>50</sup> Los semi-ejes mayor y menor también son conocidos comúnmente como los ejes semi-mayor y semi-menor.

## Datums y Coordenadas Geodésicas

Tal vez el punto más importante a tener en cuenta sobre los *datums* es el hecho de que cada uno define un concepto diferente de coordenadas geodésicas – latitud y longitud. Por lo tanto, en los casos en los que existe más de un datum para una sola posición, existe también más de un concepto de latitud y longitud. Casi se puede interpretar como una diferencia filosófica. Es común asumir que la latitud y la longitud son conceptos geográficos fijos, pero no lo son. Existen cientos de conceptos de latitud y longitud diferentes actualmente en uso (uno para cada *datum*). También puede asumirse que las diferencias entre ellos son pequeñas. No obstante, ese no es necesariamente el caso. En Norteamérica, se está llevando a cabo un cambio para convertir todo los mapeos en un *datum* recientemente definido llamado NAD83. En la Universidad de Clark, por ejemplo, si uno midiese la latitud y longitud según NAD83 y la comparase con la posición sobre el suelo de las mismas coordenadas en el sistema anterior, NAD27, la diferencia es un sobrante de ¡40 metros! Otros lugares en los Estados Unidos experimentan diferencias con un sobrante de 100 metros. Obviamente, la combinación de *datums* de fuentes medidas de acuerdo a *datums* diferentes puede conducir a discrepancias significativas.

La posibilidad de encontrar más de un *datum* en un proyecto de mapeo es bastante alta en la actualidad. En los últimos años, muchos países han tenido la necesidad de reemplazar *datums* viejos por *datums* más nuevos que proveen una mejor concordancia con las características geoidales locales. Además, los proyectos regionales o internacionales que incluyen *datums* de varios países son propensos a encontrar la presencia de múltiples *datums*. Como resultado, es imperativo ser capaz de transformar las coordenadas geodésicas de un sistema en las coordenadas de otro. En IDRISI, la opción PROJECT en el menú Reformat incorpora la transformación completa de *datums* como parte de su operación.

## Transformación Cartográfica

Una vez que se ha establecido una lógica para referirse a las posiciones terrestres y se ha realizado una serie de medidas, se necesita un medio para almacenar y analizar esas posiciones. Tradicionalmente, los mapas han sido el medio preferido tanto para el almacenamiento como para el análisis, en cambio hoy ese formato ha sido suplementado con el almacenamiento y el análisis digital. Ambos, sin embargo, comparten una característica en común – son generalmente planos. De la misma manera en que los mapas planos son un medio más manejable que los mapas en forma de globo, las coordenadas planas son un medio más manejable que las coordenadas esféricas (elipsoidales) para las aplicaciones digitales. Como resultado, las posiciones medidas son usualmente transformadas a un sistema de referencia en grilla plana antes de ser usadas.

## Proyección

El proceso de transformar coordenadas geodésicas esféricas en posiciones de coordenadas planas se conoce como proyección, y tradicionalmente se encuentra en el campo de la cartografía. Originariamente, la preocupación residía en una proyección de un solo sentido: de las coordenadas geodésicas en las coordenadas planas de una hoja de mapa. Con la aparición del SIG, en cambio, esta preocupación se ha ampliado para cubrir la necesidad de llevar a cabo transformaciones en ambas direcciones para desarrollar una base de datos unificada incorporando mapas que son todos llevados a una misma proyección. Entonces, por ejemplo, una base de datos desarrollada en una proyección de Mercator Transversal puede necesitar incorporar datos de estudios directos en coordenadas geodésicas junto con datos de mapas en varias proyecciones diferentes. Una actividad muy común en SIG es la *proyección inversa* para datos digitalizados de una proyección existente en coordenadas geodésicas y luego usar una *proyección directa* para traer los datos a una proyección final. El módulo PROJECT de IDRISI acepta ambos tipos de transformación.

La proyección de posiciones esféricas en un plano chato simplemente no se puede realizar libre de algunas (y a veces considerables) distorsiones. La ampliación y la distorsión necesarias para realizar el trabajo de transformación lleva a diferencias de escala continuas sobre la cara del mapa, lo que a la vez conduce a errores en las relaciones de distancia, área y ángulo. No obstante, a pesar de que la distorsión es inevitable, es posible modificar esa distorsión de manera tal que dichos errores se minimicen y se mantengan ciertas cualidades geométricas.


La familia de proyecciones conocida como *conformal* u *ortomorfa* es de particular importancia para SIG. Éstas son proyecciones en las que la distorsión es modificada de tal manera que las relaciones angulares son preservadas correctamente en la proximidad de cualquier posición. Tradicionalmente, el campo de los relevamientos se ha basado en la medición de relaciones angulares (usando instrumentos como el teodolito) para medir distancias exactas sobre terrenos irregulares. Como resultado, las proyecciones conformales han sido importantes para la

correcta transferencia de las medidas de campo en una base de mapa, o para la integración de nuevas investigaciones con datos de mapas existentes.

Debido a las mismas razones, las proyecciones conformales son también esenciales para muchos procedimientos de navegación. Como consecuencia, casi todas las bases topográficas son producidas sobre proyecciones conformales, las cuales forman la plataforma para todos los principales sistemas de referencia en grilla actualmente en uso.

## Sistemas de Referencia en Grilla

Un sistema de referencia en grilla puede interpretarse simplemente como una manera sistemática de relacionar las coordenadas planas de la hoja de mapa con las coordenadas geodésicas de las posiciones terrestres medidas. Claramente, un sistema de referencia en grilla necesita una proyección (generalmente una conformal). Además requiere la definición de un sistema de coordenadas cartesianas para superponerlo por encima de esa proyección. Esto requiere la identificación de una posición inicial que pueda usarse para orientar la grilla a la proyección, en forma muy similar a la manera en que se usa una posición inicial para orientar un *datum* hacia el geode. Esta posición inicial se llama el *origen verdadero* de la grilla, y está ubicada generalmente en la posición donde la distorsión es menos severa en la proyección (Figura 13-4). Luego, como en el proceso de orientar un *datum*, se establece una dirección para representar el *Norte de la grilla*. Comúnmente, esto coincide con la dirección del Norte verdadero en el origen. Sin embargo, debido a la distorsión, es imposible que el Norte verdadero y el Norte de la grilla coincidan en muchas otras ubicaciones.



Una vez que la grilla ha sido orientada hacia el origen y el Norte verdadero, se determinan un sistema de numeración y las unidades de medida. Por ejemplo, el sistema UTM (Mercator Transversal Universal) usa el Ecuador y el meridiano central de una zona de 6 grados de ancho como el origen verdadero del hemisferio Norte. El punto recibe entonces coordenadas arbitrarias de 500.000 metros Este y 0 metros Norte. Esto da un *origen falso* de 500 kilómetros hacia el Oeste del origen verdadero (ver la figura anterior). En otras palabras, el origen falso marca la posición donde el sistema de numeración es 0 en ambos ejes. En IDRISI, la lógica de numeración de un sistema de referencia en grilla siempre es establecida con la especificación de la latitud y la longitud del origen verdadero y las coordenadas arbitrarias que existen en ese punto (en este ejemplo, 500.000 E y 0 N).

## El Georeferenciamiento en IDRISI

La lógica que IDRISI usa para el georeferenciamiento es bastante simple y se basa en los temas descritos anteriormente.

Se espera que todos los archivos geográficos sean almacenados de acuerdo con un sistema de referencia en grilla donde la grilla Norte está alineada con los bordes de la imagen raster o el archivo vectorial. Como resultado, la X mínima de una imagen raster es siempre el borde izquierdo, la Y máxima es la parte superior, y así sucesivamente (Figura 13-5). Las propiedades de georeferenciamiento de una cobertura IDRISI (accesible a través de Metadata) incluyen una entrada que especifica el sistema de referencia usado por ese archivo cuando se refiere a posiciones geográficas. Los puntos particulares de ese sistema de referencia (Ej.: proyección, *datums*, origen etc.) están contenidos en un *archivo de parámetros del sistema de referencia* (.ref) (ver abajo).




Figure 13-5

Siempre que se necesite una transformación de proyección o de *datums*, el módulo PROJECT se refiere a esta información para controlar el proceso de transformación.

Cada sistema de referencia en grilla debe tener un archivo de parámetros de sistema de referencia. La única excepción a esto es un sistema identificado con la palabra clave "plano". Cualquier cobertura que indique un sistema de referencia de coordenadas plano se entiende que usa un sistema plano arbitrario para el cual los parámetros geodésicos y de proyección son desconocidos, y para el cual no existe un archivo de parámetros de sistema de referencia. Una cobertura en un sistema de referencia plano no puede ser proyectada.

Más de 400 archivos de parámetros de sistema de referencia son suministrados con IDRISI. Sin embargo, los archivos .ref pueden ser creados para cualquier sistema de referencia en grilla usando los módulos Metadata o Edit. Los detalles sobre la estructura de este simple formato de archivo de texto ASCII se encuentran más abajo en el Sistema de Ayuda on-line.

Con la finalidad de simplificar, las coordenadas geodésicas (Lat./Long.) son reconocidas como un tipo especial de sistema de referencia en grilla. Los orígenes verdadero y falso son idénticos y ocurren a 0 grados de longitud y 0 grados de latitud. Las unidades están en grados decimales o radianes. Las longitudes al Oeste del meridiano principal (Greenwich) y las latitudes al Sur del Ecuador son expresadas en números negativos. Entonces, por ejemplo, la Universidad de Clark tiene coordenadas aproximadas de -71,80; +42,27 (71°48' O; 42°16' N). Aunque las coordenadas geodésicas son verdaderamente esféricas, lógicamente éstas son tratadas aquí como un sistema de coordenadas plano. Por lo tanto, éstas son proyectadas implícitamente de acuerdo con una proyección Plate Carrée,<sup>51</sup> aunque la proyección será indicada en realidad como “ninguna”.

Tenga en cuenta que existen muchas interpretaciones posibles de los conceptos de latitud y longitud, dependiendo de los *datums* en uso. Un solo archivo “.ref” ha sido suministrado (llamado LATLONG) para el caso en que los *datums* sean WGS84. Este debe ser copiado y modificado para otras interpretaciones.

En IDRISI, el punto de registro para las imágenes raster de referenciamiento se encuentra en la esquina inferior izquierda de toda celda. Por ejemplo, al usar un sistema de referencia plano de celdas de 10 x 10 metros con una imagen de 10 columnas y 5 filas, la esquina inferior izquierda de la celda inferior izquierda tiene las coordenadas 0,0, mientras que la esquina superior derecha de la celda superior derecha tiene la posición 100,50. Observe además que esta celda inferior izquierda se considera ubicada en la columna 0 fila 4, mientras que la celda superior derecha se encuentra en la columna 10 fila 0.

Los archivos de documentación de imágenes y vectoriales de IDRISI contienen varios campos que describen el sistema de referencia del archivo. Las entradas *X mín.*, *X máx.*, *Y mín.*, *Y máx.* otorgan las coordenadas del borde de una imagen o el rectángulo delimitante de un archivo vectorial en las coordenadas de sistema de referencia. Para los archivos de imágenes, también se brinda el número de *filas* y *columnas*.

El nombre del sistema de referencia (*ref. system*) identifica el sistema de referencia del archivo, y puede ser “plano”, “lat/long”, o un sistema de referencia específico descrito por un archivo de parámetros del sistema de referencia. En el último caso, la entrada *ref. system* en el archivo de documentación debe coincidir exactamente con el nombre del archivo de parámetros del sistema de referencia, sin la extensión .ref.

La entrada *reference units* (unidades de referencia) indica la unidad de medida usada en el sistema de coordenadas de referencia (Ej.: metros).

La *unit distance* (unidad de distancia) se refiere a la distancia del terreno comprendida en la distancia de una unidad (medida en unidades de referencia) en el sistema de referencia. Entonces, por ejemplo, si la imagen hipotética de la Figura 11-6 tuviera una unidad de distancia de 2,0 y las unidades de referencia en metros, implicaría que cuando nos movemos un lugar en las coordenadas de referencia (Ej.: de X=99 a X=100) en realidad nos movemos 2,0 metros sobre el terreno. Simplemente piense en el parámetro de la unidad de distancia como un multiplicador que debería aplicarse a todas las coordenadas para producir las unidades de referencia indicadas. **La unidad de distancia es 1,0 en la mayoría de los casos.** No obstante, la unidad de distancia debe especificarse como un valor que no sea 1,0 siempre que tenga unidades de referencia que no se encuentren entre las unidades estándar aceptadas (metros, pies, millas, kilómetros, grados y radianes). Por ejemplo, un archivo de datos donde las coordenadas fueron medidas en minutos de arco (1/60 de un grado) deben tener unidades de referencia establecidas en grados y la unidad de distancia establecida en 0,016667.

En IDRISI, mientras Ud. mueve el cursor sobre una imagen visualizada, las posiciones de columna y fila de las coordenadas X e Y se indican en la barra de estado en la parte inferior de la pantalla. Los archivos vectoriales también pueden ser superpuestos (usando el Composer) sobre la imagen raster, siempre y cuando tengan el mismo sistema de referencia. *No hay necesidad de que el rectángulo delimitante del archivo vectorial coincida con el de la imagen raster.* IDRISI superpone correctamente la porción del archivo vectorial que coincide con la imagen raster visualizada. La digitalización sobre pantalla siempre genera coordenadas en el mismo sistema de referencia que el de la imagen raster visualizada.

<sup>51</sup> Tenga en cuenta, sin embargo, que las coordenadas geodésicas no son consideradas idénticas a un sistema basado en el Plate Carrée ya que no se lleva a cabo ningún nuevo esquema de numeración. PROJECT también acepta las transformaciones basadas en el Plate Carrée, donde se entiende que un verdadero sistema plano de coordenadas con su propio esquema de numeración especial ha sido superpuesto sobre las coordenadas geodésicas proyectadas.

## Archivos de Parámetros del Sistema de Referencia

Como se indicó anteriormente, IDRISI viene equipado con más de 400 archivos de parámetros de sistema de referencia.

Estos incluyen uno para las coordenadas geodésicas (latitud/longitud) usando el *datum* WGS84, 160 para el sistema UTM (uno por cada una de las 60 zonas, para el hemisferio Norte y Sur) usando el *datum* WGS84, 32 basado en la proyección Gauss-Kruger, 40 para el sistema UTM que cubre Norteamérica usando NAD27 y NAD83, y 253 para todos los Sistemas Planos de Coordenadas Estatales de los Estados Unidos (SPC) basados en las proyecciones Cónica Conforme de Lambert y Mercator Transversal. **Apéndice 3: Archivos de Parámetros del Sistema de Referencia Suministrados** detalla cada uno de estos archivos por posición geográfica. En CartaLinx, la ficha Georeferencing del diálogo *Preferences/Properties/Options* brinda una lista en el cual puede seleccionarse cualquier archivo .ref específico. Durante la instalación del programa, estos archivos suministrados son instalados en la subcarpeta \Georef de su carpeta del programa IDRISI. Los contenidos de estos archivos pueden verse con Metadata o Edit.

### Dónde se Almacenan los Archivos .ref

Como se señaló anteriormente, los archivos “.ref” suministrados son almacenados en una subcarpeta de la carpeta del programa IDRISI llamada \Georef. Si su carpeta del programa IDRISI es C:\Idrisi Selva, entonces los archivos de parámetros de sistema de referencia suministrados se encuentran en c: \Idrisi Selva\Georef. Cuando Ud. Crea nuevos archivos de parámetros de sistema de referencia, recomendamos que los guarde en esta carpeta, siempre agregándolos a su biblioteca principal de archivos de referencia. Sin embargo, los archivos de parámetros de sistema de referencia pueden almacenarse en cualquier parte. Cuando un archivo de parámetros de sistema de referencia se presenta sin su ruta en un cuadro de diálogo o macro, IDRISI siempre busca primero en la carpeta de trabajo, luego en las carpetas de recursos en el orden en que son nombradas en el proyecto actual. Si el archivo no se encuentra, IDRISI buscará luego en la subcarpeta \Georef.

### Creando Nuevos Archivos .ref

Aunque IDRISI proporciona más de 400 archivos de parámetros de sistema de referencia, muchos usuarios precisan crear nuevos archivos .ref para satisfacer las necesidades de sistemas específicos. Hay dos opciones disponibles para hacer esto:

1. Para los casos donde se requiere una versión diferente del sistema UTM, puede usarse el módulo UTMREF. Esto simplemente requerirá que Ud. ingrese el número de zona, el hemisferio (Norte o Sur) y el nombre del datum junto con sus constantes Molodensky asociadas. Las constantes pueden hallarse en el **Apéndice 2: Constantes Molodensky para Datums Geodésicos Asociados** y son usadas por PROJECT para llevar a cabo transformaciones de los *datums*. Si ingresa un *datum* que no está incluido, necesitará proporcionar el nombre del elipsoide de referencia y el largo de sus semi-ejes mayor y menor. Estas constantes para muchos elipsoides de referencia son facilitadas en el **Apéndice 1: Elipsoides de Referencia**.

2. Para todos los otros casos, se puede usar Metadata o Edit para crear el archivo apropiado. A menudo el procedimiento más fácil es usar la función copy (copiar) en IDRISI File Explorer (Explorador de Archivos) para duplicar un archivo .ref existente, y luego modificarlo usando Metadata o Edit. La siguiente sección indica la estructura y contenidos de un archivo .ref.

### La Estructura del Archivo .ref

Como todos los archivos de documentación de IDRISI, los archivos “.ref” son simples archivos de texto ASCII que pueden modificarse por medio de cualquier editor de archivo de texto ASCII.

El tipo de archivo .ref sigue las convenciones de otros archivos de documentación al tener los primeros 14 caracteres de cada línea dedicados a una descripción de campo. Aquí hay un ejemplo de un archivo de parámetros de sistema de referencia llamado UTM-19N:

ref. system	:	Universal Transverse Mercator Zone 19
projection	:	Transverse Mercator
datum	:	NAD27
delta WGS84	:	-8 160 176
ellipsoid	:	Clarke 1866
major s-ax	:	6378206.5
minor s-ax	:	6356584
origin long	:	-69
origin lat	:	0
origin X	:	500000

origin Y	:	0
scale fac	:	1
units	:	m
parameters	:	0

La primera línea es simplemente un título y no tiene uso analítico. La segunda línea indica la proyección. En la versión actual de IDRISI, se reconocen las siguientes proyecciones:

Mercator (Mercator)  
 Transverse Mercator ((Mercator Transversal)  
 Gauss-Kruger (Gauss-Krueger )  
 Lambert Conformal Conic (Cónica Conforme de Lambert)  
 Plate Carrée  
 Hammer Aitoff  
 Lambert North Polar Azimuthal Equal Area (Acimutal Equivalente Polar Norte de Lambert)  
 Lambert South Polar Azimuthal Equal Area (Acimutal Equivalente Polar Sur de Lambert)  
 Lambert Transverse Azimuthal Equal Area (Acimutal Transversal Equivalente de Lambert)  
 Lambert Oblique Azimuthal Equal Area (Acimutal Oblicua Equivalente de Lambert)  
 North Polar Stereographic (Estereográfica del Polo Norte )  
 South Polar Stereographic (Estereográfica del Polo Sur )  
 Transverse Stereographic (Estereográfica Transversal)  
 Oblique Stereographic (Estereográfica Oblicua)  
 Albers Equal Area Conic (Cónica Equivalente de Albers)  
 none (ninguna coordenadas geodésicas)

*Tenga en cuenta que cada uno de los nombres anteriores son palabras clave y deben aparecer exactamente en esta forma para ser entendidos por el módulo PROJECT.*

La próxima línea detalla el *datum* geodésico. El texto aquí es sólo informativo, a excepción de las palabras claves NAD27 y NAD83. Estos últimos dos casos son las palabras clave para las dos implementaciones existentes del datum Norteamericano. Cuando PROJECT encuentra estas palabras clave como elementos de los sistemas de entrada y de salida, usa una técnica especial (y más precisa) de transformación de *datums*. Para todos los otros casos, se usa la transformación Molodensky.

La próxima línea detalla las diferencias entre el centro (es decir, el centro de la tierra) del *datum* en uso y el centro del *datum* WGS84 (Sistema Geodésico Mundial, 1984). Los valores expresan, en metros, las diferencias en los ejes X, Y y Z respectivamente, relativas a WGS84. Éstas se conocen como las constantes Molodensky. **El Apéndice 2: Parámetros del Datum** contiene una lista de estas constantes para la mayoría de los *datums* en todo del mundo. Éstos son usados por PROJECT para llevar a cabo transformaciones de *datums* excepto en el caso de conversiones entre NAD27 y NAD83. Estas conversiones usan el procedimiento NADCON del Servicio Geodésico Nacional de Estados Unidos.

Las próximas tres líneas brindan información acerca del elipsoide de referencia. La línea que tiene el nombre del elipsoide es sólo para fines informativos. Las siguientes dos líneas describen, en metros, los semi-ejes mayor y menor del elipsoide usados por el *datum*. Estas entradas son usadas analíticamente por el módulo PROJECT. **El Apéndice 1: Elipsoides de Referencia** contiene una lista de elipsoides y el largo de sus semi-ejes.

Las próximas cuatro líneas describen el origen y el sistema de numeración del sistema de referencia. Las entradas de la *origin long* y *origin lat* indican la longitud y latitud del origen verdadero. Las entradas *origin X* y *origin Y* indican qué valores de coordenadas existen *en esa posición* en el sistema de referencia que se está describiendo.

La entrada *scale fac* indica el factor de escala para aplicar en el centro de la proyección. Un valor típico sería 1,0; aunque es igualmente permisible indicar “na” (una abreviatura de “no aplicable”). El caso más probable en el cual los usuarios necesitarán especificar otro valor que no sea 1,0 es con el sistema UTM y con otros sistemas basados en la proyección Mercator Transversal. Con el sistema UTM, el *scale fac* debe ser 0,9996.

La entrada *units* duplica la información de las unidades hallada en archivos de documentación raster y vectoriales y se incluye aquí para la confirmación de parte del sistema. Por lo tanto, en archivos de referencia y de documentación, *units* debe considerarse como entradas analíticas.



Finalmente, la entrada *parameters* indica el número de parámetros especiales incluidos con la información del archivo .ref. de las proyecciones actualmente reconocidas, sólo Lambert Conformal Conic y Alber's Equal Area Conic requieren parámetros especiales. Todas las demás deben tener un valor de 0 para esta entrada. En los casos en los que se usan las proyecciones Lambert Conformal Conic o Alber's Equal Area Conic, la entrada *parameters* debe ser 2 y luego incluir las latitudes (en grados decimales) de las dos líneas estándar (líneas sin distorsión) en las siguientes dos líneas. Aquí, por ejemplo, tenemos el archivo .ref para el Sistema Plano de Coordenadas del Estado de Massachussets, Zona 1 (SPC83MA1), basado en el *datum* NAD83:

```
ref. system      :      Massachusetts State Plane Coordinate System Mainland Zone
projection       :      Lambert Conformal Conic
datum           :      NAD83
delta WGS84     :      0 0 0
ellipsoid       :      GRS80
major s-ax      :      6378137
minor s-ax      :      6356752.31
origin long     :      -71.5
origin lat      :      41
origin X        :      200000
origin Y        :      750000
scale fac       :      na
units           :      m
parameters      :      2
stand ln 1      :      41.72
stand ln 2      :      42.68
```

Observe que la latitud de la línea estándar “más baja” (es decir, aquella que se encuentra más cerca del Ecuador) está primera en la lista y la de la línea estándar latitudinalmente “más alta” se encuentra segunda en la lista. Las adiciones futuras de otras proyecciones pueden imponer la necesidad de parámetros especiales. No obstante, en esta versión, sólo aquellos sistemas de referencia basados en las proyecciones Lambert Conformal Conic y Alber's Equal Area Conic requieren parámetros especiales.

## Transformaciones de Proyección y Datum

La opción PROJECT del menú COVERAGE en CartaLinx provee transformación completa entre sistemas de referencia. Como consecuencia, lleva a cabo la transformación de las características de la proyección y el *datum*.

Las transformaciones de proyección para todas las proyecciones avaladas se realizan usando fórmulas elipsoidales a 2 cm. del suelo. Como CartaLinx usa números de punto flotante de doble precisión (15 cifras significativas) para la representación de datos de coordenadas, esta precisión se mantiene en todos los resultados. Sin embargo, tenga en cuenta que la precisión de las coordenadas exportadas depende de la precisión numérica utilizada por el formato de exportación en uso.

Para las transformaciones de *datum*, el principal método usado es la transformación Molodensky descrita en DMA (1987). Siempre que las palabras claves “NAD27” y “NAD83” se hallan en una transformación se usa el procedimiento más preciso NADCON del Servicio Geodésico Nacional de EE.UU. (ver Dewhurst, 1990). *Este último procedimiento debe usarse sólo dentro de la parte continental de Estados Unidos.* Para otras regiones cubiertas por el *Datum* Norteamericano, no utilice las palabras claves NAD27 o NAD83, sino otra palabra del campo del *datum*, e indique las constantes de transformación Molodensky correctas del **Apéndice 2: Parámetros del Datum**.<sup>52</sup>

## Algoritmos Usados por PROJECT

Las fórmulas de proyección elipsoidal inversa y directa fueron tomadas de Snyder (1987). Para las transformaciones de *datum*, se usa el procedimiento de transformación Molodensky (DMA, 1987). Sin embargo, para el caso específico de las transformaciones NAD27/NAD83 dentro del territorio continental de EE.UU., se usa el procedimiento NADCON del Servicio Geodésico Nacional de EE.UU. Este procedimiento se describe en Dewhurst (1990) y está acompañado por archivos de datos relevantes. Resumiendo, el procedimiento incluye una matriz de

<sup>52</sup> Observe que mientras existe un grupo de constantes para el Dato Norteamericano como una unidad, también existen las constantes Molodensky para porciones más específicas de las regiones cubiertas para mejorar la precisión de la transformación.

correcciones para las longitudes y latitudes que son ingresadas como una tabla de búsqueda bidimensional. Los valores de la corrección final son entonces interpolados entre los cuatro valores más cercanos en la matriz usando una interpolación bilineal. Para facilitar esto, los archivos de datos NADCON para el territorio continental de EE.UU. fueron convertidos en imágenes IDRISI. Estas imágenes están contenidas en el subdirectorio GEOREF en el directorio del programa IDRISI. Hay dos de estos archivos, NADUSLON y NADUSLAT, para las correcciones de longitud y latitud respectivamente.

## Lectura Complementaria

La Geodesia no es un tema familiar para muchos usuarios de SIG. Sin embargo, como se ve en el material de este capítulo, es esencial para un desarrollo efectivo de bases de datos. Las siguientes lecturas proveen un buen resumen de los temas relacionados:

Burkard, R.K., (1964) *Geodesy for the Layman*, (St. Louis, MO: USAF Aeronautical Chart and Information Center).

Smith, J.R., (1988) *Basic Geodesy*, (Rancho Cordova, CA: Landmark Enterprises).

Para las proyecciones, hay pocos textos relacionados con el alcance y el enfoque de:

Maling, D.H., (1973) *Coordinate Systems and Map Projections*, (London: George Phillip and Son).

Snyder, J.P., (1987) *Map Projections: A Working Manual*. U.S. Geological Survey Professional Paper 1395, (Washington, DC: US Government Printing Office).

Finalmente, con respecto a los procedimientos usados para las transformaciones de datum, consulte:

DMA, (1987) *Department of Defense World Geodetic System 1984: Its Definition and Relationships with Local Geodetic Datums*, DMA TR 8350.2, (Washington, DC: The Defense Mapping Agency).

Dewhurst, W.T., (1990) NADCON: *The Application of Minimum Curvature-Derived Surfaces in the Transformation of Positional Data from the North American Datum of 1927 to the North American Datum of 1983*, NOAA Technical Memorandum NOS NGS-50, (Rockville, MD: National Geodetic Information Center).

# CAPÍTULO 13 - Apoyo en la Toma de Decisiones: Análisis de la Estrategia de Decisiones

Con el crecimiento rápido de la población y las expectativas continuas de crecimiento en el nivel de vida, las presiones en el uso de los recursos naturales se han vuelto intensas. Para el administrador de recursos, la tarea de la asignación de recursos efectiva se ha tornado bastante dificultosa. Las opciones claras son pocas y el uso creciente de más terrenos marginales lo sitúa a uno cara a cara frente a un amplio rango de incertidumbres. Además, existe un ambiente muy dinámico sujeto a los sustanciales y complejos impactos de la intervención humana. Esto resulta en un proceso de toma de decisiones dominado por la incertidumbre y los riesgos consecuentes para la persona que toma las decisiones.

En los últimos años, se ha puesto un interés considerable en el uso de SIG como un sistema de apoyo en la toma de decisiones. Para algunos, esta función consiste en informar en el proceso de la toma de decisiones. Sin embargo, es más probable que la mayor contribución se dé en el campo de la asignación de recursos.

Desde hace varios años, el personal de investigación de Clark Labs está especialmente involucrado en el uso de SIG como una extensión directa del proceso humano de toma de decisiones – particularmente en el contexto de las decisiones en la asignación de recursos. Sin embargo, nuestras investigaciones iniciales en esta área indicaban que las herramientas disponibles en este tipo de análisis eran bastante pobres. A pesar de los enérgicos desarrollos en el campo de la Ciencia de la Decisión, el impacto provocado en el desarrollo de herramientas software había sido apenas perceptible. Sin embargo, al mismo tiempo había un claro interés por parte de un grupo creciente de investigadores en el tema SIG de incorporar algunos de estos avances en ese campo. Como consecuencia, en los primeros años de la década del 90', nos embarcamos en un proyecto, junto con el UNITAR, para investigar en el tema y para desarrollar una serie de herramientas software para la asignación de recursos. Estas primero fueron distribuidas con la Versión 4.1 de la versión MS-DOS de IDRISI, con un enfoque especial en los procedimientos para la toma de decisiones Multicriterio y Multiobjetivo – un área que se puede denominar *Análisis de la Estrategia de Decisiones*. Desde entonces, hemos continuado este desarrollo, específicamente en el área del *Manejo de la Incertidumbre*.

La incertidumbre no es simplemente un problema referido a los datos. En cambio, es una característica inherente del proceso mismo de la toma de decisiones. Debido a las presiones crecientes sobre el proceso de asignación de recursos, debemos reconocer a la incertidumbre no como una falla de la cual lamentarse y a la cual tal vez ignorar, sino como un hecho del proceso de la toma de decisiones que necesita ser entendido y observado. El Manejo de la Incertidumbre yace en el mismo centro de la toma de decisiones efectiva y tiene un papel muy especial en los sistemas software que aceptan SIG. La siguiente discusión es presentada en dos partes. Este capítulo explora el Análisis de la Estrategia de Decisiones y el capítulo siguiente aborda el Manejo de la Incertidumbre.

## Introducción<sup>53</sup>

La Teoría de la Decisión se ocupa de la lógica por la cual uno llega a una opción entre alternativas. Estas alternativas varían de problema a problema. Pueden ser acciones alternativas, hipótesis alternativas acerca de un fenómeno, objetos alternativos para incluir en un grupo, etc. En el contexto de SIG, es útil distinguir entre decisiones de políticas y decisiones de asignación de recursos. Esta última incluye decisiones que afectan directamente la utilización de recursos (Ej.: suelo), mientras que la primera sólo pretende influir el comportamiento decisivo de otros quienes a su vez harán compromisos con los recursos. Los SIG poseen un potencial considerable en ambos campos.

En el contexto de las decisiones de políticas, los SIG se usan generalmente para informar a la persona que toma las decisiones.

Sin embargo, también posee potencial (casi sin utilizar en este momento) como una herramienta de modelación de procesos, en la cual pueden simularse los efectos espaciales de una conducta de decisión prevista. La modelación de la simulación, particularmente de la calidad espacial de temas socio-económicos y su relación con la naturaleza, aún

---

<sup>53</sup> El material introductorio en este capítulo está adaptado de Eastman, J.R., 1993. Decision Theory and GIS, *Proceedings, Africa GIS '93*, UNITAR, Geneva.

se encuentra en su infancia. No obstante, se espera que en el futuro los SIG jueguen un papel cada vez más sofisticado en esta área.

Las decisiones de asignación de recursos son también candidatas principales para el análisis con SIG. Es más, la evaluación y la asignación del terreno son unas de las actividades más importantes del desarrollo de recursos (FAO, 1976). Con la aparición de los SIG, ahora tenemos la oportunidad de realizar un proceso de evaluación del terreno más racional. No obstante, sin los procedimientos y las herramientas para el desarrollo de reglas de decisión y la modelación predictiva de resultados esperados, esta oportunidad quedará en gran medida frustrada. Los SIG han sido lentos para satisfacer las necesidades de los que toman decisiones y para solucionar los problemas de incertidumbre que llevan a los riesgos de decisión. En un intento por solucionar estos inconvenientes, Clark Labs ha trabajado con la colaboración de UNITAR para crear una serie de herramientas de apoyo en la toma de decisiones para el sistema software IDRISI.

Aunque hoy existe una literatura bastante extensa sobre la toma de decisiones en los campos de la Ciencia de la Administración, las Operaciones de Investigación y la Ciencia Regional (a veces asociados bajo el nombre de Ciencia de la Decisión), desafortunadamente hay un uso de la terminología bastante divergente (Ej.: ver Rosenthal, 1985). De acuerdo con esto, hemos adoptado el siguiente grupo de definiciones operacionales que creemos están en línea con el impulso que da la literatura de la Ciencia de la Decisión y expresan el contexto de la toma de decisiones en SIG.

## Definiciones

### Decisión

Una decisión es una elección entre alternativas. Las alternativas pueden representar diferentes caminos de acción, diferentes hipótesis sobre la naturaleza de una característica, diferentes clasificaciones, etc. Llamamos a este grupo de alternativas *marco de decisiones*. Entonces, por ejemplo, el marco de decisiones para un problema de zonificación puede ser [comercial residencial industrial]. El marco de decisiones, sin embargo, debe distinguirse de los individuos a los que se aplica la decisión. A esto le llamamos *grupo candidato*. Por ejemplo, siguiendo con el ejemplo de zonificación anterior, el grupo de posiciones (píxeles) en la imagen que será zonificado es el grupo candidato. Finalmente, un *grupo de decisiones* es aquél que incluye todos los individuos a los que se les asigna una alternativa específica del marco de decisiones. Entonces, por ejemplo, todos los píxeles asignados a la zona residencial constituyen un grupo de decisiones. De manera similar, aquellos que pertenecen a la zona comercial constituyen otro. Por lo tanto, otra definición de una decisión sería considerarla el acto de asignación de un individuo a un grupo de decisiones. Alternativamente, se puede interpretar como una elección de caracterizaciones alternativas para un individuo.

### Criterio

Un criterio es la base para una decisión que puede medirse y evaluarse. Es la evidencia sobre la cual puede asignarse un individuo a un grupo de decisiones. El criterio puede ser de dos tipos: factores y restricciones, y puede estar relacionado con los atributos del individuo o bien con un grupo de decisiones entero.

### Factores

Un factor es un criterio que mejora o reduce la aptitud de una alternativa específica para la actividad en consideración.

Por lo tanto, se mide comúnmente en una escala continua. Por ejemplo, una compañía de forestación puede determinar que mientras más profunda sea la pendiente, más costoso es transportar la madera. Como resultado, las mejores áreas para la tala son aquellas con pendientes suaves – mientras más suave, mejor. Los factores también se conocen como *variables de decisión* en la literatura de la programación matemática (ver Feiring, 1986) y *variables estructurales* en la literatura de la programación de objetivo lineal (ver Ignizio, 1985).

### Restricciones

Una restricción sirve para limitar las alternativas en consideración. Un buen ejemplo de una restricción sería la exclusión del desarrollo de áreas designadas como reservas naturales. Otro podría ser la estipulación de que ningún desarrollo se lleve a cabo en las pendientes que exceden un gradiente del 30%. En muchos casos, las restricciones se expresan en la forma de un mapa booleano (lógico): las áreas excluidas de la consideración están codificadas con un 0 y aquellas incluidas están codificadas con un 1. No obstante, en algunas ocasiones, la restricción se expresa como alguna característica que debe poseer el grupo de decisiones. Por ejemplo, se puede necesitar que el área total de

tierras seleccionadas para el desarrollo no sea menor a 5000 hectáreas, o que el grupo de decisiones consista en una sola área contigua. Restricciones como ésta a menudo se llaman *metas* (Ignizio, 1985) o *objetivos* (Rosenthal, 1985). Sin importar cuál, ambas formas de restricción tienen el mismo significado final – limitar las alternativas bajo consideración.

Aunque los factores y las restricciones son comúnmente vistos como formas de criterio muy diferentes, más adelante se presentará en este capítulo un material que muestra que estas perspectivas populares son simplemente casos especiales de una continua variación en el grado en el que los criterios intercambian su influencia sobre la solución, y en el grado de conservación en riesgo (o de otra manera, pesimismo u optimismo) que uno desea introducir en la estrategia de decisión elegida. Entonces, las restricciones muy duras ilustradas anteriormente se verán como los extremos *rígidos* de una clase más general de criterio *difuso* que encierra todas estas posibilidades. Es más, se mostrará que los criterios continuos (los cuales usualmente interpretamos como factores) pueden servir como restricciones *suaves* cuando el intercambio es eliminado. En el análisis de ecosistemas y la evaluación de la adaptabilidad del suelo, este tipo de factor se llama *factor limitante*, el cual es claramente un tipo de restricción.

## Regla de Decisión

El procedimiento por el cual se eligen y combinan los criterios para llegar a una evaluación particular, y por el cual las evaluaciones son comparadas y aplicadas se conoce como una regla de decisión. Una regla de decisión puede ser tan simple como un umbral aplicado a un solo criterio (como todas las regiones con pendientes menores a 35% serán zonificadas como aptas para el desarrollo) o puede ser tan compleja como una que incluye la comparación de varias evaluaciones multicriterio.

Las reglas de decisión usualmente contienen procedimientos para combinar criterios en un solo índice compuesto y una declaración de cómo deben compararse las alternativas usando este índice. Por ejemplo, podemos definir un mapa de adecuación compuesto para la agricultura basado en una combinación lineal ponderada de información sobre suelos, pendientes y la distancia desde el mercado. La regla hasta puede determinar que se seleccionen las mejores 5000 hectáreas. Esto puede lograrse eligiendo ese grupo de celdas raster, que hacen un total de 5000 hectáreas, en el cual la suma de adecuaciones es maximizada. Se puede lograr de igual manera ordenando las celdas por rango y tomando suficientes celdas del mayor rango para producir un total de 5000 hectáreas. La anterior se puede llamar una *función de elección* (*choice function*) (conocida como una *función objetiva* o un *índice de ejecución*- *objective function or performance index* en la literatura de la matemática de programación – ver Diamond and Wright, 1989) mientras que la segunda puede denominarse una *heurística de elección* (*choice heuristic*).

## Función de Elección

Las funciones de elección proveen un medio matemático para comparar alternativas. Debido a que involucran una forma de optimización (como la maximización o minimización de alguna característica medible), en teoría requieren que cada alternativa se evalúe por vez. Sin embargo, en algunas ocasiones, existen técnicas para limitar la evaluación sólo en aquellas alternativas probables. Por ejemplo, el Método Simple en la programación lineal (ver Feiring, 1986) está específicamente diseñado para evitar evaluaciones no necesarias.

## Heurística de Elección

Las heurísticas de elección especifican un procedimiento a seguir en lugar de una función a evaluar. En algunos casos, producen un resultado idéntico al de una función de elección (como el ejemplo anterior de los rangos), mientras que en otros simplemente proveen una aproximación cercana. Las heurísticas de elección son comúnmente usadas porque a menudo son más simples de entender y más fáciles de implementar.

## Objetivo

Las reglas de decisión están estructuradas en el contexto de un objetivo específico. La naturaleza de ese objetivo, y la manera en que es entendido por la persona que toma las decisiones (es decir, sus motivos) sirven como una enérgica fuerza conductora en el desarrollo de una regla de decisión específica. Un objetivo es entonces una *perspectiva* que sirve para guiar la estructuración de las reglas de decisión<sup>54</sup> Por ejemplo, podemos tener el objetivo establecido para determinar las áreas aptas para la tala de árboles para madera. Sin embargo, nuestra perspectiva puede ser una que trata de minimizar el impacto de la cosecha en los usos recreacionales del área. La elección del criterio para usar y los pesos para asignarles es bastante diferente de la de un grupo cuya preocupación principal es

<sup>54</sup> Es importante destacar aquí que estamos usando una definición un poco más amplia del término objetivo que la que se halla en la literatura de la programación de objetivos (ver Ignizio, 1985). En la programación de objetivos, el término objetivo es sinónimo del término función objetiva usado en la programación matemática y de función de elección usado aquí.

la maximización de las ganancias. Los objetivos se ocupan por lo tanto de los temas del motivo y la perspectiva social.

## Evaluación

El proceso real de aplicación de la regla de decisión se llama evaluación.

### Evaluaciones Multicriterio

Para cubrir un objetivo específico, a menudo ocurre que se necesita evaluar varios criterios. Tal procedimiento se llama *Evaluación Multicriterio* (Voogd, 1983; Carver, 1991). Otro término que a veces se usa es *modelación*. No obstante, este término se evita aquí ya que la forma en que los criterios son combinados está muy influenciada por el objetivo de la decisión.

La evaluación multicriterio (MCE) se logra comúnmente a través de uno de dos procedimientos diferentes. El primero implica una *supercapa booleana* por la cual todos los criterios son reducidos a declaraciones lógicas de adecuación y luego combinados por medio de uno o más operadores como la intersección (AND) y la unión (OR). El segundo se conoce como *combinación lineal ponderada* (WLC) donde los criterios continuos (*factores*) son estandarizados en un rango numérico común, y luego combinados por medio de un promedio ponderado. El resultado es un mapeo de adecuación continuo que luego puede ser enmascarado por una o más restricciones booleanas para dar lugar a los criterios cualitativos, y finalmente se impone un umbral para producir una decisión final.

A pesar de que estos dos procedimientos están bien establecidos en los SIG, frecuentemente conducen a resultados diferentes porque realizan declaraciones muy diferentes acerca de cómo deben evaluarse los criterios. En el caso de la evaluación booleana, se usa una forma muy extrema de decisiones. Si los criterios son combinados con un AND lógico (operador de intersección), una posición debe cumplir con *cada* criterio para que ésta sea incluida en el grupo de decisiones. Si aún un simple criterio no se cumple, la posición será excluida. Tal procedimiento es esencialmente adverso al riesgo, y selecciona posiciones basándose en la estrategia más cautelosa posible – una posición logra ser elegida sólo si su peor cualidad (y por lo tanto, todas las cualidades) pasan la prueba. Por otra parte, si se usa un OR (unión) lógico, ocurre lo contrario – una posición será incluida en el grupo de decisiones si sólo un único criterio pasa la prueba. Esta es una estrategia bastante especuladora, con un riesgo incluido (aparentemente) sustancial.

Ahora compare estas estrategias con aquellas representadas por la combinación lineal ponderada (WLC). Con la WLC, los criterios pueden intercambiar sus cualidades. Una cualidad muy pobre puede ser compensada con un número de cualidades muy favorables. Este operador no representa un AND ni un OR – yace en alguna parte entre estos extremos. No es ni adverso ni favorable al riesgo.

Debido a razones que tienen mucho que ver con la facilidad con la que estos enfoques pueden implementarse, la estrategia booleana domina los enfoques vectoriales a MCE, mientras que la WLC domina las soluciones en los sistemas raster. Pero claramente, ninguno es mejor que el otro – simplemente representan dos perspectivas muy diferentes sobre el proceso de decisión – lo que se puede llamar estrategia de decisión. IDRISI además incluye una tercera opción para la Evaluación Multicriterio, conocida como promedio ponderado ordenado (OWA) (Eastman and Jiang, 1996). Este método ofrece un espectro completo de estrategias de decisión a lo largo de las dimensiones primarias del grado de intercambio involucrado y del grado de riesgo en la solución.

### Evaluaciones Multiobjetivo

A pesar de que muchas de las decisiones que tomamos son impulsadas por un solo objetivo, también sucede que necesitamos tomar decisiones que cumplan con varios objetivos. Un problema Multiobjetivo se presenta siempre que tenemos dos grupos candidatos (es decir, grupos de entidades) que comparten miembros. Estos objetivos pueden ser de naturaleza complementaria o conflictiva (Carver, 1991 : 322).

#### Objetivos Complementarios

Con los objetivos complementarios o no conflictivos, las áreas de terreno pueden satisfacer más de un objetivo, es decir, un pixel individual puede pertenecer a más de un grupo de decisiones. Las áreas deseadas son aquellas que juntas sirven estos objetivos en alguna forma especificada. Por ejemplo, si deseamos asignar una cierta cantidad de terreno para usos combinados de recreación y conservación de la vida salvaje, las áreas óptimas son aquellas que satisfacen ambos objetivos al grado máximo posible.

#### Objetivos Conflictivos

Con los objetivos conflictivos, la competición acontece por el terreno disponible, ya que éste puede usarse para uno

u otro objetivo, no para ambos. Por ejemplo, podemos necesitar resolver el problema de asignación de terreno para la cosecha de madera y la conservación de la vida salvaje. Obviamente, las dos no pueden coexistir. Cómo compiten exactamente, y sobre qué base uno le ganará al otro, dependerá de la naturaleza de la regla de decisión desarrollada.

En los casos de objetivos complementarios, las decisiones multiobjetivo a menudo pueden ser solucionadas a través de una extensión *jerárquica* del proceso de evaluación multicriterio. Por ejemplo, podemos asignar un peso a cada uno de los objetivos y usarlos, junto con los mapas de adecuación elaborados para cada uno, para combinarlos en un solo mapa de adecuación. Esto indicará el grado en el cuál las áreas cumplen todos los objetivos considerados (ver Voogd, 1983). Sin embargo, con los objetivos conflictivos el procedimiento está más comprometido.

Con los objetivos conflictivos, a veces es posible ordenarlos de acuerdo al rango y alcanzar una solución por prioridad (Rosenthal, 1985). En estos casos, las necesidades de objetivos de rangos más elevados se cubren antes de que se traten las necesidades de aquellos objetivos de rangos menores. No obstante, a menudo esto no es posible, y la solución más común para los objetivos conflictivos es el desarrollo de una solución de *compromiso*. Sin dudas, las técnicas comúnmente usadas para resolver objetivos conflictivos son aquellas que incluyen la optimización de una función de elección como la programación matemática (Fiering, 1986) o la programación de objetivos (Ignizio, 1985). En ambas, la preocupación consiste en generar una asignación del terreno que maximice o minimice una función objetiva sujeta a una serie de restricciones.

## Incertidumbre y Riesgo

Claramente, la información es vital en el proceso de la toma de decisiones. Sin embargo, rara vez disponemos de información perfecta. Esto conduce a la incertidumbre, de la cual se pueden identificar dos fuentes: *incertidumbre de la base de datos* y *de la regla de decisión*.

### Incertidumbre de la Base de Datos

La incertidumbre de la base de datos es aquella que reside en nuestras evaluaciones de los criterios que están enumeradas en la regla de decisión. El error de medición es la fuente principal de tal incertidumbre. Por ejemplo, una pendiente de 35% puede representar un umbral importante. No obstante, debido a la forma en que se determinan las pendientes, puede existir alguna incertidumbre sobre si la medida de la pendiente de 34%, realmente es 34%. A pesar de que confiemos en gran medida que ésta probablemente es de 34% *aproximadamente*, también debemos admitir que existe una mínima probabilidad de que sea tan alta como de 36%. Nuestra expresión de la incertidumbre de la base de datos es posible que se base en una teoría de probabilidad.

### Incertidumbre de la Regla de Decisión

La incertidumbre de la regla de decisión es la que se genera a partir de la manera en que se combinan y evalúan los criterios para llegar a una decisión. Una forma muy simple de incertidumbre de la regla de decisión es la que se relaciona con los parámetros o umbrales empleados en la regla de decisión. Un tema más complejo es aquél relacionado con la misma estructura de la regla de decisión. Éste a veces se llama *error de especificación* (Alonso, 1968), debido a las incertidumbres que nacen de la especificación de la relación entre los criterios (como un modelo) de tal manera que la evidencia adecuada esté disponible para la evaluación apropiada de la hipótesis bajo investigación.

### Incertidumbre de la Regla de Decisión y Evidencia Directa: Grupos Difusos versus Rígidos

Un tema clave en la incertidumbre de la regla de decisión es el de establecer la relación entre la evidencia y el grupo de decisiones. En la mayoría de los casos, podemos establecer una relación directa entre los dos, en el sentido de que podemos definir el grupo de decisiones por los atributos medibles que sus miembros deben poseer. En algunos casos, estos atributos son rígidos y claros. Por ejemplo, podemos definir esas líneas de canales que necesitan ser remplazadas como líneas con un material y una edad particular. Sin embargo, con frecuencia los atributos que poseen son difusos en lugar de rígidos. Por ejemplo, podemos definir áreas adecuadas para la tala de árboles como aquellas áreas forestadas que poseen pendientes suaves y se encuentran cerca de un camino. ¿Qué es una pendiente suave? Si especificamos que una pendiente es suave cuando tiene una gradiente menor al 5%, ¿significa esto que una pendiente de 5,0001% no es suave?

Obviamente no hay un criterio bien definido aquí. Tales clases se llaman grupos *difusos* (Zadeh, 1965) y generalmente son definidos por un grupo de función de pertenencia. Entonces podemos decidir que cualquier pendiente menor al 2% es sin dudas una pendiente suave, y que cualquier pendiente mayor al 10% es sin dudas profunda, pero la pertenencia en el grupo suave cae gradualmente de una gradiente de 1,0 a un 2% a una gradiente de 0.0 a un 10%. Una pendiente del 5% puede considerarse entonces con un valor de pertenencia de solo 0,7 en el grupo llamado “suave”. Un grupo similar de consideraciones también encierra el concepto de estar “cerca” de un camino.

Los grupos difusos son extremadamente comunes en los problemas de decisión que se presentan en SIG. Éstos constituyen una forma de incertidumbre, pero no es incertidumbre de medición. El tema de qué compone una pendiente está por encima y por debajo del tema de si una pendiente medida es en realidad lo que se registra. Es una forma de incertidumbre que se encuentra en el mismo corazón del concepto de los factores desarrollados anteriormente. *Los factores continuos de la toma de decisiones multicriterio son funciones de pertenencia de grupos difusos, mientras que las restricciones booleanas son funciones de pertenencia de grupos rígidos.* Pero debería reconocerse que los términos factor y restricción implican más que las funciones de pertenencia difusa o rígida. En verdad, estos términos también dan algún significado a la forma en la cual éstos son agregados con otra información.

### **Incetidumbre de la Regla de Decisión y Evidencia Indirecta: Bayer versus Dempster Shafer**

No toda la evidencia puede relacionarse directamente con el grupo de decisiones. En algunas ocasiones sólo tenemos una relación indirecta entre los dos. En este caso, podemos establecer lo que llamamos una *función de creencia* del grado en el cual la evidencia implica la pertenencia en el grupo de decisiones. Dos herramientas importantes para lograr esto son la Teoría de Probabilidad Bayesiana y la Teoría de Evidencia Dempster-Shafer. Éstas serán tratadas en más detalle más adelante en la Parte B de este capítulo llamada Manejo de la Incertidumbre.

### **Riesgo de la Decisión**

El Riesgo de la Decisión puede entenderse como la probabilidad de que la decisión tomada sea incorrecta.<sup>55</sup> El riesgo nace como un resultado de la incertidumbre, y su evaluación, por lo tanto, requiere una combinación de estimaciones de incertidumbre de varias fuentes involucradas (incertidumbre de base de datos y de regla de decisión) y de procedimientos, como la teoría de Probabilidad Bayesiana, a través de los cuales éste se puede determinar. Nuevamente, este tema se discutirá detalladamente en la Parte B de este capítulo.

## **Una Tipología de Decisiones**

Dadas estas definiciones, es posible establecer una tipología de decisiones muy amplia como se ilustra en la Figura 12-1.

	Críterio Simple	Críterio-Múltiple
Objetivo Simple		
Objetivo Multiple		

**Figura 12-1**

Las decisiones pueden caracterizarse con una naturaleza uniobjetivo o multiobjetivo, basándose en un unicriterio o en un multicriterio. Mientras uno está ocupado ocasionalmente con problemas de unicriterio, la mayoría de los problemas tratados en SIG son de naturaleza multicriterio. Por ejemplo, podemos identificar áreas de interés para la erosión del suelo basándonos en pendientes, uso del suelo, tipo de suelo, etc. En estas instancias, nuestro interés yace en cómo combinar estos criterios para llegar a una decisión compuesta. Como consecuencia, la primer área principal en SIG con respecto a la Teoría de Decisión es la Evaluación Multicriterio.

Comúnmente, tratamos problemas de decisión de esta naturaleza desde una sola perspectiva. Sin embargo, en muchos casos, el problema es en realidad de naturaleza multiobjetiva (Diamond and Wright, 1988). Los problemas multiobjetivos aparecen siempre que los mismos recursos pertenecen a más de un grupo candidato. Entonces, por ejemplo, una compañía papelera puede incluir todas las áreas boscosas en su grupo candidato para considerarlas como áreas de tala, mientras que un grupo de conservación puede incluir áreas boscosas en un grupo candidato más grande de áreas naturales para ser protegidas. Entonces, cualquier intento por reconciliar sus pretensiones potenciales en este grupo de recursos comunes presenta un problema de decisión multiobjetivo.

<sup>55</sup> Tenga en cuenta que los diferentes campos de la ciencia definen el riesgo de diferentes maneras. Por ejemplo, algunas disciplinas modifican la definición dada aquí e incluyen la medida de los costos o las consecuencias de una decisión errónea (permitiendo entonces una relación directa con el análisis de costo/beneficio). Los procedimientos desarrollados en IDRISI no excluyen tal extensión. Hemos tratado de presentar una perspectiva bastante simple que puede usarse como una construcción para interpretaciones más específicas.



A pesar del predominio de los problemas multiobjetivo, el software SIG actual carece en gran medida de técnicas para tratar este tipo de decisión. La mayoría de los ejemplos de procedimientos de decisión multiobjetivo en la literatura han abordado el problema a través del uso de la optimización de la programación lineal (Ej.: Janssen y Rietveld 1990; Carver, 1991; Campbell y otros, 1992; Wright y otros, 1983). Sin embargo, en la mayoría de los casos, éstos han sido tratados como problemas de elección entre un número limitado (Ej.: menos de 20) de sitios candidatos previamente aislados en un sistema vectorial. El volumen de datos asociados con aplicaciones raster

(donde cada pixel es una alternativa elegible) claramente excede las capacidades computacionales del ambiente de la computación actual. Además, la terminología y los procedimientos de la programación lineal son desconocidos para la mayoría de las personas que toman decisiones y son complejos y carecen de intuición por naturaleza. Como consecuencia, la segunda área principal de la Teoría de Decisión de importancia para SIG es la Asignación de Terreno Multiobjetivo. Aquí, se focalizará sobre una heurística de decisión simple apropiada para las necesidades especiales de SIG raster.

## Toma de Decisiones Multicriterio en SIG

Como se indicó anteriormente, el tema principal en la Evaluación Multicriterio se ocupa de cómo combinar la información de varios criterios para formar un solo índice de evaluación. En el caso de los criterios booleanos (restricciones), la solución usualmente se encuentra en la unión (OR lógico) o intersección (AND lógico) de las condiciones. No obstante, para los factores continuos se usa más comúnmente una combinación lineal ponderada (Voogd, 1983: 120). Con una combinación lineal ponderada, los factores son combinados aplicando un peso a cada uno seguido por una sumatoria de los resultados para producir un mapa de adecuación, es decir:

$$S = \sum w_i x_i \quad \text{donde} \quad \begin{array}{ll} S = & \text{adecuación} \\ w_i = & \text{peso de factor } i \\ x_i = & \text{valor del criterio de factor } i \end{array}$$

Este procedimiento es familiar en SIG y tiene una forma muy similar a la naturaleza de una ecuación de regresión. En los casos donde también se aplican las restricciones booleanas, el procedimiento puede modificarse multiplicando la adecuación calculada a partir de los factores por el producto de las restricciones, es decir:

$$S = \sum w_i x_i * \Pi c_j \quad \text{donde} \quad \begin{array}{ll} c_j = & \text{valor del criterio de restricción } j \\ \Pi = & \text{producto} \end{array}$$

Todos los software SIG proveen las herramientas básicas para evaluar tal modelo. Además, en IDRISI, se ha desarrollado un módulo especial llamado MCE para facilitar este proceso. Sin embargo, el módulo MCE ofrece además un procedimiento especial llamado Promedio Ponderado Ordenado (*Ordered Weighted Average*) que extiende en gran medida las opciones de estrategia de decisión disponibles. El procedimiento se discutirá ampliamente en la sección Evaluación más adelante. Por ahora, los temas principales se relacionan con la estandarización de los valores de criterios y el desarrollo de los pesos.

## Valores de Criterios

Debido a las diferentes escalas sobre las cuales se miden los criterios, es necesario estandarizar<sup>56</sup> los factores antes de combinarlos usando las fórmulas anteriores, y transformarlos, si es necesario, de manera tal que todos los mapas de factores se correlacionen positivamente con la adecuación.<sup>57</sup> Voogd (1983: 77-84) resume una variedad de procedimientos para la estandarización, usualmente por medio de los valores mínimos y máximos como puntos de escala. El más simple es una escala lineal como:

$$x_i = (R_i - R_{\min}) / (R_{\max} - R_{\min}) * \text{rango\_estandarizado} \quad \text{donde } R = \text{valor puro}$$

No obstante, si reconocemos que los factores continuos son en realidad grupos difusos, fácilmente reconocemos esto sólo como una de varias funciones posibles de pertenencia de grupos. En IDRISI, el módulo llamado FUZZY (difuso) sirve para la estandarización de factores usando un rango completo de funciones de pertenencia de grupos

<sup>56</sup> Al usar el término *estandarización*, hemos adoptado la terminología de Voogd (1983), aunque este proceso debería llamarse *normalización*.

<sup>57</sup> Entonces, por ejemplo, si los sitios cercanos a un camino fuesen más ventajosos para el asentamiento industrial que aquellos alejados, un mapa de distancia debería ser transformado en uno que exprese la proximidad.

difusos. El módulo es rápido y fácil de usar, y provee la opción de estandarizar factores en una escala de números reales de 0-1 o en una escala byte de 0-255. Se recomienda la segunda opción porque el módulo MCE ha sido optimizado para la velocidad usando una estandarización de nivel 0-255. El valor más alto de la escala estandarizada debe representar el caso de *mayor* probabilidad de pertenencia al grupo de decisiones.

Un tema crítico en la estandarización de factores es la elección de los puntos finales en los cuales la pertenencia de grupo alcanza 0,0 ó 1,0 (ó 0 y 255). Nuestra propia investigación no aconseja usar una escala lineal a ciegas (o cualquier otra escala) entre los valores mínimos y máximos de la imagen. Al establecer estos puntos críticos para la función de pertenencia de grupo, es importante considerar su significado inherente. Entonces, por ejemplo, si consideramos que el desarrollo industrial debe situarse tan lejos de una reserva natural como sea posible, sería peligroso implementar esto sin una consideración cuidadosa. Literalmente, si el mapa cubriese una distancia a unos 100 Km. de la reserva, entonces el punto más alejado de la reserva tendría un valor de 1,0 (ó 255 en una escala byte). Por lo tanto, al usar una función lineal, una posición a 5 Km. de la reserva tendría un valor estandarizado de solo 0,05 (13 en una escala byte).

Puede ser que el argumento principal fuese el ruido y las molestias menores de las ciudades locales, para los cuales una distancia de solo 5 Km. hubiese sido igualmente buena como de 100 Km. de distancia. Entonces el valor estandarizado debiera haber sido en realidad de 1,0 (255). Si se llevase a cabo un MCE usando el escalado lineal ciego, los sitios en el rango de unos pocos 10s de Km. hubiesen sido seriamente devaluados cuando en realidad podrían haber sido bastante buenos. En este caso, los sitios críticos recomendados para la escala debieran haber sido 0 y 5 Km. Al desarrollar factores estandarizados usando FUZZY, se debe considerar cuidadosamente el significado inherente de los puntos finales elegidos.

## Ponderación de los Criterios

Existe una variedad de técnicas para la creación de pesos. En los casos muy simples, la asignación de la ponderación de los criterios puede lograrse dividiendo 1,0 por los criterios. (A veces es útil para las personas pensar en “gastar” un dólar, por ejemplo, entre los criterios). Sin embargo, cuando el número de criterios es mayor a unos pocos, y las consideraciones son muchas, se torna bastante dificultoso hacer evaluaciones de pesos de un grupo completo. Dividir la información en comparaciones simples por pares en los cuales solo dos criterios necesitan considerarse por vez puede facilitar en gran medida el proceso de ponderación, y probablemente produzcan un grupo más robusto. Un método de comparación por pares posee la ventaja agregada de proveer una estructura organizada para las discusiones de grupo, y de ayudar al grupo de la toma de decisiones a perfeccionar las áreas de acuerdo y desacuerdo en la creación de la ponderación de los criterios.

La técnica aquí descrita e implementada en IDRISI es la de comparaciones por pares desarrollada por Saaty (1977) en el contexto de un proceso de toma de decisión conocido como el Proceso de Jerarquía Analítica (AHP). La primera introducción de esta técnica a una aplicación SIG fue la de Rao y otros (1991), aunque el procedimiento fue desarrollado fuera del software SIG usando una variedad de recursos analíticos.

En el procedimiento para la Evaluación Multicriterio usando la combinación lineal ponderada expresada anteriormente, es necesario que los pesos sumen en uno. En la técnica de Saaty, los pesos de esta naturaleza pueden derivarse tomando el *vector propio* principal de una matriz recíproca cuadrada de comparaciones por pares entre criterios. Las comparaciones se ocupan de la importancia relativa de los dos criterios involucrados al determinar la adecuación para el objetivo planteado. Los puntajes se proveen sobre una escala continua de 9 puntos (Figura 12-2). Por ejemplo, si uno considera que la proximidad a los caminos es mucho más importante que el gradiente de las pendientes para determinar la adecuación para un establecimiento industrial, uno debe ingresar un 7 de esta escala. Si ocurre el caso contrario (la gradiente de las pendientes es mucho más importante que la proximidad a los caminos), uno debe ingresar 1/7.

1/9	1/7	1/5	1/3	1	3	5	7	9
sumamente	muy fuertemente	fuertemente	moderadamente	igualmente	moderadamente	fuertemente	muy fuertemente	sumamente
menos importante								más importante

**Figura 12-2.** La Escala de Posición Continua.

Al desarrollar los pesos, un individuo o un grupo compara cada par posible e ingresa los puntajes en una matriz de comparación por pares (Figura 12-3). Ya que la matriz es simétrica, en realidad necesita ser llenada solo la mitad triangular inferior. El resto de las celdas son simplemente la recíproca de la mitad triangular inferior (por ejemplo,

debido a que el puntaje de la gradiente de pendiente relativa a la proximidad a la ciudad es 4, el puntaje de la proximidad a la ciudad relativa a la gradiente de pendiente será de 1/4). Observe que donde existe evidencia empírica acerca de la eficacia relativa de un par de factores, también se puede emplear esta evidencia.

Puntaje del Factor de Fila Relativo al Factor de Columna

	Proximidad al Camino	Proximidad a la Ciudad	Gradiente de la Pendiente	Establecimiento Small Holder	Distancia al Parque
Proximidad al Camino	1				
Proximidad a la Ciudad	1/3	1			
Gradiente de la Pendiente	1	4	1		
Establecimiento Small Holder	1/7	2	1/7	1	
Distancia al Parque	1/2	2	1/2	4	1

**Figura 12-3.** Un ejemplo de una matriz de comparación por pares para evaluar la importancia comparativa de cinco factores para la adecuación del desarrollo industrial.

El procedimiento entonces requiere que el *vector propio* principal de la matriz de comparación por pares se compute para producir un grupo de pesos *mejor adecuado* (Figura 12-4). Si no hay procedimiento disponible para realizar esto, una buena aproximación a este resultado puede lograrse calculando los pesos con cada columna y luego promediar todas las columnas. Por ejemplo, si tomamos la primera columna de cifras, éstas suman 2,98. Al dividir cada una de las entradas en la primera columna por 2,98 se producen pesos de 0,34; 0,11; 0,34; 0,05 y 0,17 (compare con los valores en la Figura 12-4). Repetir esto por cada columna y promediar los pesos sobre las columnas, usualmente brinda una buena aproximación a los valores calculados por el *vector propio* principal. En el caso de IDRISI, en cambio, un módulo especial llamado WEIGHT ha sido desarrollado para calcular el *vector propio* principal directamente. Observe que estos pesos se sumarán en uno, como lo requiere el procedimiento de combinación lineal ponderada.

Debido a que la matriz completa de comparación por pares contiene múltiples rutas por las cuales puede evaluarse la importancia relativa de los criterios, es posible también determinar el grado de consistencia usado para desarrollar los puntajes. Saaty (1977) muestra el procedimiento por el cual puede producirse un índice de consistencia conocido como *tasa de consistencia* (Figura 12-4). Esta tasa de consistencia (CR) indica la probabilidad de que los puntajes de la matriz se generen de manera aleatoria. Saaty señala que las matrices con puntajes CR mayores que 0,10 deben ser re-evaluadas.

Además de la tasa de consistencia completa, también es posible analizar la matriz para determinar dónde aparecen las inconsistencias. Esto también ha sido desarrollado como parte del módulo WEIGHT de IDRISI.

Proximidad a camino	0.33
Proximidad a ciudad	0.08
Gradiente de la Pendiente	0.34
Establecimiento Smal Holder	0.07
Distancia al parque	0.18

Tasa de consistencia 0.06

**Figure 12-4.** Pesos sacados calculando el vector propio principal de la matriz de comparación por pares.

## Evaluación

Una vez que los mapas de criterios (factores y restricciones) han sido creados, se lleva a cabo un paso de evaluación (o agregado) para combinar la información de los factores y las restricciones. El módulo MCE ofrece tres lógicas para la evaluación/agregado de múltiples criterios: intersección booleana, combinación lineal ponderada (WLC) y el promedio ponderado ordenado (OWA).

### MCE e Intersección Booleana

El tipo más simple de agregado es la intersección booleana o AND lógico. Este método sólo se usa cuando los mapas de factores han sido estrictamente clasificados en imágenes booleanas adecuadas/no adecuadas con valores 1 y 0. La evaluación es meramente la multiplicación de todas las imágenes.

### MCE y Combinación Lineal Ponderada

La derivación de la ponderación de los criterios(o factores) está explicada más arriba. El método de agregado de combinación lineal ponderada (WLC) multiplica cada mapa estandarizado de factores (es decir, cada celda raster dentro de cada mapa) por el peso de factores y luego suma los resultados. Debido a que el grupo de pesos de factor para una evaluación debe sumar 1 (uno), el mapa de adecuación resultante tiene el mismo rango de valores que el de los mapas de factores estandarizados usados. Este resultado luego se multiplica por cada una de las restricciones por vez para “desenmascarar” áreas no adecuadas. Todos estos pasos pueden realizarse usando una combinación de SCALAR y OVERLAY, o bien usando el Image Calculador. Sin embargo, el módulo MCE está diseñado para facilitar el proceso.

La opción WLC en el módulo MCE requiere que Ud. especifique el número de criterios (tanto factores como restricciones), sus nombres y los pesos para aplicar a los factores. Todos los factores deben ser estandarizados en un rango byte (0-255). (Si posee factores en formato real, entonces utilice una de las opciones exceptuando las MCE mencionadas anteriormente). El resultado es un mapa de *adecuación* enmascarado por las restricciones especificadas.

### MCE y el Promedio Ponderado Ordenado

En su utilización e implementación, el enfoque del promedio ponderado ordenado es similar a la WLC. El cuadro de diálogo de la opción OWA es casi idéntico al de WLC, con la excepción de que aparece un segundo grupo de pesos. Este segundo grupo de pesos, los pesos de orden, controla la manera en la cual los factores ponderados son agregados (Eastman and Jiang, 1996; Yager, 1988). Es más, WLC resulta ser una variante de la técnica OWA. Para introducir la técnica OWA, primero repasemos la WLC en términos de dos nuevos conceptos: intercambio y riesgo.

#### Intercambio

Los pesos de factores son pesos que se aplican en factores específicos, es decir, todos los píxeles de una imagen particular de factores reciben el mismo peso de factor. Éstos indican el grado relativo de importancia que cada factor posee para determinar la adecuación de un objetivo. En el caso de WLC, el peso dado a cada factor determina además cómo intercambiará los factores relativos con otros. Por ejemplo, un factor con un peso de factor alto puede intercambiar o compensar los valores pobres de otros factores, aún cuando el valor de adecuación no ponderado para ese factor de peso alto no sea particularmente bueno. En contraste, un factor con un valor de adecuación alto pero con un peso de factor pequeño sólo puede compensar levemente los valores pobres de otros factores. Los pesos de factor determinan cómo los factores realizan el intercambio, pero, como se describe más adelante, los pesos de orden determinan el nivel *valor* de intercambio permitido.

#### Riesgo

Los enfoques booleanos son funciones extremas que resultan en soluciones adversas al riesgo cuando se emplea el operador AND o bien en soluciones riesgosas cuando se emplea el operador OR.<sup>58</sup> En el primero, un valor alto de adecuación agregada para una posición dada (pixel) sólo es posible si *todos* los factores tienen valores altos. En el segundo, un valor alto en cualquier factor produce un valor agregado alto, aún si todos los demás factores tienen valores muy bajos. La operación AND puede describirse como el *mínimo*, ya que el valor mínimo para cualquier pixel determina el valor agregado final. De manera similar, la operación OR puede llamarse el *máximo*, ya que el valor máximo para cualquier pixel determina el valor agregado final. La solución AND es *adversa al riesgo* porque podemos estar seguros que el valor para cada factor es al menos tan bueno como el valor agregado final. La solución

---

<sup>58</sup> La lógica de las operaciones booleanas AND y OR es implementada con grupos difusos como el mínimo y el máximo. Entonces, como en esta discusión estamos considerando valores de factores continuos en lugar de imágenes 0-1 booleanas, el AND lógico es evaluado como el valor mínimo para un pixel a través de todos los factores. Y el OR lógico es evaluado como el valor máximo para un pixel a través de todos los factores.

OR es *riesgosa* porque el valor agregado final sólo nos dice el valor de adecuación para el único factor más adecuado.

El enfoque WLC es una técnica de promedio que suaviza o ablanda las decisiones duras del enfoque booleano y evita los extremos. En realidad, dado un continuo de riesgo de mínimo a máximo, la WLC queda exactamente en el medio; no es adversa al riesgo ni tampoco riesgosa.

Otro ejemplo importante de la tabla es donde los pesos de orden son iguales, [.33, .33, .33]. Aquí todas las posiciones evaluadas tienen el mismo peso; esto hace el intercambio completamente posible y posiciona el análisis exactamente a mitad de camino entre AND y OR. Los pesos de orden iguales producen el mismo resultado que WLC.


En los tres casos, los pesos de orden han determinado no sólo el nivel de intercambio sino también han situado el análisis en un rango desde (el operador AND mínimo y adverso al riesgo) al (operador OR máximo y riesgoso).

Como se observa en la tabla, los pesos de orden en la opción OWA de MCE no están limitados a estas tres posibilidades, por el contrario, se les puede asignar cualquier combinación de valores que sume 1,0. Cualquier asignación de pesos de orden resulta en una regla de decisión que se encuentra en alguna parte de un espacio de estrategia de decisión triangular definida por las dimensiones de riesgo e intercambio como se muestra en la Figura 12-5.

Sin importar si la mayoría del peso es asignado a la izquierda, derecha o centro de los pesos de orden, igualmente determina la posición en la dimensión de riesgo. El operador lógico AND es la combinación más adversa al riesgo y el operador lógico OR es la combinación más riesgosa. Cuando los pesos de orden son predominantemente asignados a los factores con menor puntaje, hay una aversión al riesgo mayor (más de un enfoque AND). Cuando los pesos de orden son principalmente asignados a los factores con mayor puntaje, hay una predisposición al riesgo mayor (más de un enfoque OR). Como se discutió anteriormente, los pesos de orden iguales producen una solución ubicada en el centro del eje de riesgo.

Pesos de Orden			Resultado
Min (1)	(2)	Max (3)	
1.00	0.00	0.00	174
0.90	0.10	0.00	175
0.80	0.20	0.00	177
0.70	0.20	0.10	179
0.50	0.30	0.20	183
0.40	0.30	0.30	186
0.33	0.33	0.33	187
0.30	0.30	0.40	189
0.20	0.30	0.50	191
0.10	0.20	0.70	196
0.00	0.20	0.80	198
0.00	0.10	0.90	200
0.00	0.00	1.00	201

El grado de intercambio está gobernado por la relativa distribución de los pesos de orden entre los factores evaluados. Entonces, si la suma de los pesos de orden está repartida en partes iguales entre los factores, hay un intercambio fuerte. En cambio, si todo el peso es asignado a un solo rango de factores, no hay intercambio. (Puede ser de ayuda interpretar esto en términos de un gráfico de pesos de orden, con el rango de orden en el eje x y el valor del peso de orden en el eje y. si el gráfico tiene un pico agudo, hay poco intercambio. Si el gráfico es relativamente chato, hay un intercambio fuerte.)



**Figura 12-5**

El método OWA es particularmente interesante porque provee este rango de procedimientos de agrupamiento. En un extremo (AND lógico), cada criterio se considera necesario (pero no suficiente en sí mismo) para incluirlo en el grupo de decisión. En el otro extremo (OR lógico), cada criterio es suficiente en sí mismo para avalar la inclusión en el grupo de decisión sin modificación por parte de otros factores. Por lo tanto, la posición del operador de combinación lineal ponderada a mitad de camino entre estos extremos no es ninguna novedad. Este operador no

considera que los criterios sean necesarios ni suficientes – el fuerte apoyo por la inclusión en el grupo de decisión de un criterio puede ser nivelado por un apoyo menor de otro. Entonces, ofrece un intercambio completo.

### Usando OWA

Dada esta introducción, vale la pena considerar cómo uno debe usar la opción OWA de MCE. Algunos puntos a seguir son:

1. Divida sus criterios en tres grupos: restricciones duras, factores que no deben realizar intercambios y factores que sí. Por ejemplo, los factores con contenido monetario por lo general realizan intercambios, mientras que aquellos asociados con temas de seguridad usualmente no realizan intercambio.
2. Si Ud. encuentra que tiene dos tipos de factores, los que realizan intercambios y los que no, separe su consideración en dos pasos de análisis. En el primero, agregue los factores que realizan intercambios usando la opción OWA. Ud. Puede dominar el grado de intercambio manipulando los pesos de orden. Luego utilice el resultado del primer paso como un factor nuevo que se incluye en el análisis de aquellos que no realizan intercambios.
3. Si ejecuta un análisis sin ningún intercambio, los pesos de factores no tiene un significado real y pueden establecerse en cualquier valor.

### Completando la Evaluación

Una vez que se ha preparado un mapa de adecuación, es común decidir, como paso final, qué celdas deben pertenecer al grupo que cumple con un objetivo de área de asignación de terreno (el grupo de decisión). Por ejemplo, si se creó un mapa de adecuación para el desarrollo industrial, entonces podemos determinar qué áreas constituyen las *mejores* 5000 hectáreas que serán asignadas. Extrañamente, esta es un área donde la mayoría de los sistemas raster tienen dificultad para lograr una solución exacta. Una solución sería usar una función de elección donde se elija ese grupo de celdas lo que minimiza la suma de adecuaciones. Sin embargo, el número de combinaciones que necesita ser evaluado es prohibitivo en un SIG raster. Como resultado, elegimos usar una simple heurística de elección – para ordenar las celdas de acuerdo al rango y elegir tantas celdas de puntaje alto como sean necesarias para cumplir con el objetivo del área. En IDRISI, se encuentra disponible un módulo llamado RANK que permite una evaluación rápida de las celdas en una imagen.

Además, permite usar una segunda imagen para resolver el rango de los enlaces. El mapa evaluado puede ser reclasificado para extraer los puntajes más altos para cumplir con el objetivo del área.

## Toma de Decisiones Multiobjetivo en SIG

Las decisiones multiobjetivo son tan comunes en el manejo del ambiente que es sorprendente que herramientas específicas para tratarlas aún no hayan sido más desarrolladas dentro de SIG. Los pocos ejemplos que uno encuentra en la literatura tienden a concentrarse en el uso de las herramientas de programación matemática fuera de SIG, o están limitados a casos de objetivos complementarios.

### Objetivos Complementarios

Como se indicó anteriormente, el caso de los objetivos complementarios puede tratarse de manera bastante simple por medio de una extensión jerárquica del proceso de evaluación multicriterio (Ej.: Carver, 1991). Aquí, un grupo de mapas de adecuación, cada uno derivado en el contexto de un objetivo específico, sirven como los factores para una nueva evaluación en la cual los objetivos son ponderados y combinados por una sumatoria lineal. Desde que la lógica que avala esto es de uso múltiple, también tiene sentido multiplicar el resultado por todas las restricciones asociadas con los objetivos componentes.


### Objetivos en Conflicto

Con los objetivos en conflicto, el terreno puede ser asignado a un objetivo solamente (aunque los modelos híbridos pueden combinar objetivos complementarios y en conflicto). Como señalamos anteriormente, una solución posible se encuentra en darle distintas prioridades a los objetivos (Rosenthal, 1985). Después de que los objetivos han sido ordenados según la prioridad, se satisfacen primero las necesidades de aquellos objetivos con mayor prioridad (a través del orden de rango de las celdas y de la reclasificación para cumplir con los objetivos de área) antes que las necesidades de aquellos con menor prioridad. Esto se realiza al satisfacer sucesivamente las necesidades de los objetivos con mayor prioridad, y luego eliminando (como una nueva restricción) las áreas tomadas por ese objetivo


para consideración de todos los objetivos restantes. Una solución de prioridad se logra fácilmente con el uso de los módulos RANK, RECLASS y OVERLAY en IDRISI. Sin embargo, son raros los casos en los que una solución de *prioridad* tiene sentido. Más frecuentemente se requiere una solución de *compromiso*.

Como se dijo antes, las soluciones de compromiso para el problema multiobjetivo se han tratado comúnmente a través del uso de herramientas de programación matemática fuera de SIG (Ej.: Diamond y Wright, 1988; Janssen y Rietveld, 1990; Campbell, y otros, 1992). Las soluciones de programación matemática (como la programación lineal o entera) pueden funcionar bastante bien en los casos donde sólo se incluye un pequeño número de alternativas. Sin embargo, en el caso de SIG raster, los grupos de datos masivos involucrados usualmente exceden la capacidad de las computadoras de hoy en día. Además, los conceptos y la metodología de la programación lineal y entera no son particularmente posibles para un amplio grupo de personas que toman decisiones. Como resultado, hemos buscado una solución al problema de la asignación de terreno multiobjetivo bajo condiciones de objetivos en conflicto de manera tal que los grupos grandes de datos raster puedan manejarse usando procedimientos que poseen una atracción intuitiva inmediata.

El procedimiento que hemos desarrollado es una extensión de la heurística de decisión usada para la asignación de terreno con problemas de objetivos únicos. Esto está mejor ilustrado en el diagrama de la Figura 12-6a. Cada uno de los mapas de adecuación puede interpretarse como un eje en un espacio multidimensional. Aquí consideramos solo dos objetivos para propósitos de explicación simple. Sin embargo, puede usarse cualquier número de objetivos.



**Figura 12-6a**



**Figura 12-6b**

Cada celda raster en la imagen puede localizarse dentro de este espacio de decisión de acuerdo con su nivel de adecuación sobre cada uno de los objetivos. Para encontrar las mejores hectáreas x de terreno para el Objetivo 1, simplemente necesitamos mover una línea de decisión hacia abajo desde la cima (es decir, bien a la derecha) del eje de adecuación del Objetivo 1 hasta capturar la cantidad suficiente de las mejores celdas raster para cumplir con el propósito de nuestra área.

Podemos hacer lo mismo con el eje de adecuación del Objetivo 2 para capturar las mejores hectáreas y de terreno para éste. Como puede observarse en la Figura 12-6a, esto divide el espacio de decisión en cuatro regiones – mejores áreas para el Objetivo 1 y no adecuadas para el Objetivo 2, mejores áreas para el Objetivo 2 y no adecuadas para el Objetivo 1, áreas no adecuadas para ninguno y áreas juzgadas como adecuadas para ambos. Esta última representa áreas de conflicto.

Para resolver estas áreas de conflicto, se usa una simple división de las celdas afectadas. Como se ve en la Figura 12-6b, el espacio de decisión también se puede dividir en dos regiones más: aquellas más cercanas al *punto ideal* para el Objetivo 1 y aquellas más cercanas al punto ideal para el Objetivo 2. El punto ideal representa el mejor caso posible – una celda que es adecuada al máximo para un objetivo y al mínimo para cualquier otra cosa. Para resolver la zona de conflicto, la línea que divide estas dos regiones es superpuesta sobre esta zona y las celdas luego son asignadas a su punto ideal más cercano. Debido a que la región de conflicto se dividirá entre los objetivos, ambos objetivos no llegarán a lograr sus propósitos de área. Como resultado, el proceso se repetirá con la disminución de las líneas de decisión para ambos objetivos para ganar más territorio. El proceso de resolver conflictos y de disminuir las líneas de decisión se repite una y otra vez hasta lograr los objetivos de área exactos.

Se debe tener en cuenta que una línea de 45 grados entre un par de objetivos supone que tiene el mismo peso en la resolución de los conflictos. Sin embargo, se les puede dar diferentes pesos. Los pesos diferentes tienen el efecto de



cambiar el ángulo de esta línea divisora. En realidad, la tangente del ángulo es igual a la tasa de los pesos asignada a esos objetivos.

Además se debe observar que de la misma manera en que es necesario estandarizar los criterios para la evaluación multicriterio, también esto es necesario para la evaluación multiobjetivo. El proceso incluye una conciliación de los histogramas para los dos mapas de adecuación. En los casos en que las distribuciones son normales, la conversión a los valores estándar (usando el módulo llamado STANDARD) será apropiada. Sin embargo, en muchos casos, las distribuciones no son normales. En estos casos, el ajuste de los histogramas se logra más fácilmente por medio de una técnica no paramétrica conocida como ecualización de histogramas. Esta es una opción estándar en muchos sistemas de procesamiento de imágenes como IDRISI. Sin embargo, también se da el caso en que los mapas de adecuación evaluados y producidos por el módulo RANK poseen histogramas ecualizados (es decir, un histograma de un mapa evaluado es uniforme). Esto es fortuito ya que la lógica señalada en la Figura 12-6a se logra mejor por medio de la reclasificación de los mapas de adecuación evaluados.

Como resultado de las consideraciones anteriores, el módulo llamado MOLA (Multi-Objective Land Allocation-Asignación de Terreno Multiobjetiva) ha sido desarrollado para llevar a cabo la solución de compromiso del problema multiobjetivo. MOLA requiere los nombres de los objetivos y sus pesos relativos, los nombres de los mapas de adecuación evaluados para cada uno, y las áreas que deben ser asignadas a cada uno. Luego reclasifica repetidamente los mapas de adecuación evaluados para realizar una asignación de primer paso, verifica los conflictos, y después asigna los conflictos basándose en una regla de distancia mínima al punto ideal empleando los valores ponderados.

## Un Ejemplo Elaborado

Para ilustrar estos procedimientos multicriterio y multiobjetivo, consideraremos el siguiente ejemplo de la creación de un mapa de zonificación para regular la expansión de la industria de alfombras (una de las industrias más grandes y crecientes de Nepal) dentro de las áreas agrícolas del Valle de Katmandú en Nepal. El problema es zonificar 1500 hectáreas de tierras actualmente agrícolas afuera de los caminos de Katmandú para una mayor expansión de la industria de alfombras. Además, se zonificarán 6000 hectáreas para la protección especial de la agricultura. El problema se encuentra claramente en el campo de los problemas de decisión multicriterio y multiobjetivo. En este caso, tenemos dos objetivos: proteger las mejores tierras para la agricultura y al mismo tiempo encontrar otras tierras más adecuadas para la industria de alfombras. Debido a que la tierra sólo puede ser asignada a uno de estos usos por vez, los objetivos deben verse como en conflicto (es decir, pueden competir potencialmente por las mismas tierras). Además, la evaluación de cada uno de estos objetivos puede requerir criterios múltiples.

En la ilustración a continuación, se presenta una solución al problema multiobjetivo y multicriterio creada con un grupo de funcionarios del gobierno de Nepal como parte de un seminario avanzado en SIG<sup>59</sup>. Mientras que el escenario se desarrolló puramente con el propósito de demostrar las técnicas usadas y el resultado no representa una decisión de política verdadera, esta es una solución que incorpora un trabajo de campo sustancial y también las perspectivas de personas reconocidas que toman decisiones. El procedimiento sigue la lógica en la que cada uno de los dos objetivos primero se trata como un problema separado de evaluación multicriterio. El resultado consiste en dos mapas de adecuación separados (uno para cada objetivo) que luego son comparados para llegar a una sola solución que nivele las necesidades de los dos objetivos competidores.

## 1. Resolviendo las Evaluaciones de un Solo Objetivo Multicriterio

### 1.1 Estableciendo los Criterios: Factores y Restricciones

El grupo que toma las decisiones identificó cinco factores relevantes para el establecimiento de la industria de alfombras: proximidad a una fuente de agua (para usar en el teñido y lavado de las alfombras), proximidad a los caminos (para minimizar los costos de construcción de caminos), proximidad a una fuente de energía, proximidad al mercado y gradiente de las pendientes. Para la agricultura identificaron tres de los mismos factores: proximidad a una fuente de agua (para la irrigación), proximidad al mercado y gradiente de las pendientes, así como también un cuarto factor, capacidad del suelo. En ambos casos, identificaron las mismas restricciones: la asignación estaría limitada a áreas fuera de los caminos periféricos que rodean Katmandú, terreno actualmente con algún tipo de uso agrícola y gradientes de pendientes menores de 100%. Para las imágenes de factores, la distancia a la fuente de agua, a los caminos y a las líneas eléctricas fue calculada en base a la distancia física. Y la proximidad al mercado fue

<sup>59</sup> El seminario fue organizado por UNITAR en el Centro Internacional para el Desarrollo Integrado de Montaña (ICIMOD) en Nepal, del 28 de septiembre al 2 de octubre de 1992.



desarrollada como una superficie de costo de distancia (constituyendo las fricciones variables de las clases de caminos).

## 1.2 Estandarizando los Factores

Cada una de las restricciones fue desarrollada como un mapa booleano, mientras que los factores fueron estandarizados usando el módulo FUZZY para que los resultados representasen una pertenencia difusa en el grupo de decisión. Por ejemplo, para la asignación de la industria de alfombras, el mapa del factor de proximidad a la fuente de agua fue estandarizado usando una función de pertenencia difusa sigmoide, monotónicamente decreciente con los puntos de control a 10 y 700 metros. Entonces, a las áreas a menos de 10 metros se les asignó un grupo de pertenencia de 255 (en una escala de 0-255), a aquellas entre los 10 y los 700 metros se les asignó un valor progresivamente decreciente de 255 a 0 como en una curva en forma de s, y a aquellas más allá de los 700 metros de un río fueron consideradas como demasiado lejanas (es decir, se les asignó un valor de 0). La Figura 12-7 ilustra los resultados estandarizados de los cinco factores y las restricciones para la asignación de la industria de carpetas.

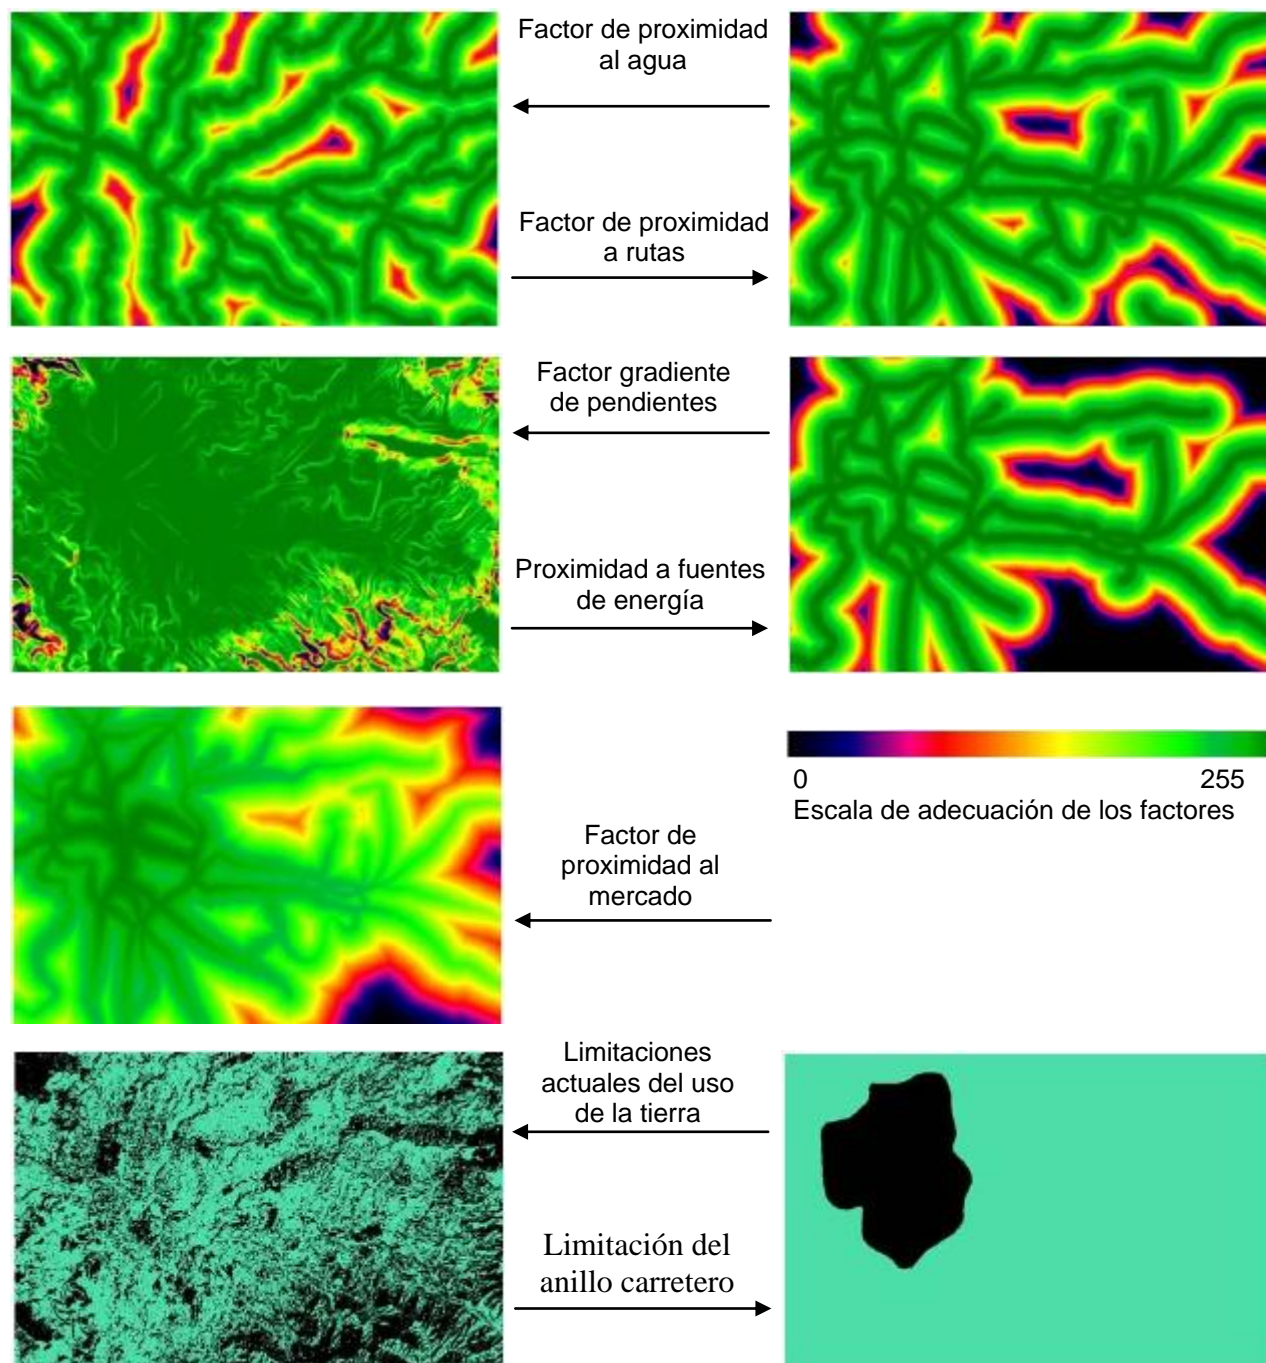


Figura 12-7. Factores de la industria de alfombras y limitaciones.

### 1.3 Estableciendo los Pesos de Factores

El próximo paso fue establecer un grupo de pesos para cada uno de los factores. En la naturaleza de un grupo foco, el analista de SIG trabajó con las personas que toman las decisiones como un solo grupo para completar una matriz de comparación por pares. A cada persona que toma decisiones se le pidió que estimara un valor y luego indicara por qué él o ella asignaron el valor. Luego se le preguntó al grupo si estaba de acuerdo. Otras discusiones resultaron, a menudo con sugerencias, en valores diferentes. Finalmente, si otra persona exponía un buen caso para un valor diferente y tenía bastante apoyo, a la persona original que propuso el valor se le preguntaba si estaría dispuesto/a a cambiar (la decisión final en realidad la tomaba el evaluador original). No fue difícil llegar a un acuerdo usando este procedimiento. Se ha descubierto a través de repetidos experimentos con esta técnica que los únicos casos donde existió un fuerte desacuerdo fueron aquellos en los que se identificó eventualmente una nueva variable necesaria de incorporar. Esto es quizás el mayor valor de la técnica de comparación por pares – es muy efectiva en descubrir criterios pasados por alto y en lograr un consenso sobre los pesos por medio de la participación directa de las personas que toman las decisiones.


Una vez que se llenaron las matrices de comparación por pares, el módulo WEIGHT fue usado para identificar las inconsistencias y para desarrollar los pesos mejor adecuados. La Figura 12-8 muestra los pesos de factores evaluados para la adecuación con el fin de crear una industria de alfombras.

Factor	Peso de Factor
Proximidad a una fuente de Agua	0,51
Proximidad a los Caminos	0,05
Proximidad a una fuente de Energía	0,25
Accesibilidad al Mercado	0,16
Pendientes Bajas	0,03

**Figura 12-8**

### 1.4 Realizando la Evaluación Multicriterio

Una vez que se establecieron los pesos, se usó el módulo MCE (para la Evaluación Multicriterio) para combinar los factores y las restricciones en la forma de una combinación lineal ponderada (opción de WLC). El procedimiento es optimizado para una mejor velocidad y tiene el efecto de multiplicar cada factor por su peso, sumando los resultados y luego multiplicando sucesivamente el resultado por cada una de las restricciones. Debido a que los pesos suman 1,0; los mapas de adecuación resultantes tienen un rango de 0-255. La Figura 12-9 muestra el resultado de evaluaciones multicriterio separadas para derivar mapas de adecuación para las industrias de alfombra y agrícola.



**Figura 12-9** Imágenes Compuestas de Adecuación para la Industria de las Alfombras (izq.) y la agricultura (derecha). La escala de adecuación corresponde a la misma de la Figura 12-7.

## 2. Resolviendo el Problema Multiobjetivo de Asignación de Terreno


Una vez que los mapas de adecuación multicriterio han sido creados para cada objetivo, se puede tratar el problema de decisión multiobjetivo.

### 2.1 Estandarizando los Mapas de Adecuación Uniobjetivo

El primer paso fue usar el módulo RANK para evaluar el orden de las celdas en cada uno de los dos mapas de adecuación. Esto prepara los datos para usarlos con el procedimiento MOLA y tiene el efecto adicional de estandarizar los mapas de adecuación usando una técnica de ecualización de histograma no paramétrica. Los valores se desarrollaron en orden descendente (es decir, el mejor valor fue de 1). En ambos casos los valores enlazados fueron resueltos examinando el otro mapa de adecuación y colocando los valores en orden reverso a la adecuación de ese mapa. Esto preserva la lógica básica usada en la resolución de conflictos de los puntos ideales no correlacionados para los objetivos en conflicto.

### 2.2 Resolviendo el Problema Multiobjetivo

El segundo paso fue enviar los mapas de adecuación evaluados al procedimiento MOLA. Éste requiere los nombres de los objetivos, el peso relativo y el área para asignarle a cada uno. El módulo entonces realiza el procedimiento iterativo de asignar las celdas mejor valuadas a cada objetivo según los propósitos de área, buscando los conflictos y resolviéndolos en base a la lógica ponderada de la distancia mínima al punto ideal. La Figura 12-10 expone el resultado final, logrado luego de 6 repeticiones.



**Figura 12-10.** Asignación final a las industrias de alfombras (rojo) y agricultura (verde).

## Guía de Apoyo en la Toma de Decisiones Multiobjetivo y Multicriterio

La Guía de Apoyo en la Toma de Decisiones (es decir, un grupo de diálogos enlazados) ayuda a guiar a los usuarios en los procedimientos de asignación de recursos multiobjetivo y multicriterio como los ilustrados anteriormente. Los pasos conducen al usuario a través de cada fase en la construcción de un modelo completo y graban las reglas de decisión en un archivo que puede almacenarse y luego ser modificado. Una sección especial del Sistema de Ayuda provee información adicional para cada pantalla de la guía. Los usuarios novatos encontrarán que la guía es muy útil para organizar su progreso a través de la secuencia de pasos, mientras que los usuarios avanzados apreciarán la habilidad para almacenar un modelo MCE/MOLA completo que puede alterarse y ejecutarse repetidamente para producir asignaciones finales alternativas. La guía se inicia desde el menú Analysis/Decision Support.



## Comentario Final

Las herramientas de apoyo para la toma de decisiones ofrecidas en IDRISI aún se encuentran en activo desarrollo. Por lo tanto, le damos la bienvenida a comentarios y observaciones escritas para mejorar aún más los módulos y perfeccionar su aplicación en situaciones reales.

## Referencias / Lecturas Complementarias

- Alonso, W., 1968. Predicting Best with Imperfect Data, *Journal of the American Institute of Planners*, 34: 248-255.
- Carver, S.J., 1991. Integrating Multi-Criteria Evaluation with Geographical Information Systems, *International Journal of Geographical Information Systems* 5(3): 321-339.
- Campbell, J.C., Radke, J., Gless, J.T. y Wirtshafter, R.M., 1992. An Application of Linear Programming and Geographic Information Systems: Cropland Allocation in Antigua, *Environment and Planning A*, 24: 535-549.
- Diamond, J.T. y Wright, J.R., 1988. Design of an Integrated Spatial Information System for Multiobjective Land-Use Planning, *Environment and Planning B: Planning and Design*, 15: 205-214.
- Diamond, J.T. y Wright, J.R., 1989. Efficient Land Allocation, *Journal of Urban Planning and Development*, 115(2): 81-96.
- Eastman, J.R., 1996. Uncertainty and Decision Risk in Multi-Criteria Evaluation: Implications for GIS Software Design, *Proceedings, UN University International Institute for Software Technology Expert Group Workshop on Software Technology for Agenda'21: Decision Support Systems*, del 26 de febrero al 8 de marzo.
- Eastman, J.R., y Jiang, H., 1996. Fuzzy Measures in Multi-Criteria Evaluation, *Proceedings, Second International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Studies*, May 21-23, Fort Collins, Colorado, 527-534.
- Eastman, J.R., Jin, W., Kyem, P.A.K., y Toledano, J., 1995. Raster Procedures for Multi-Criteria/Multi-Objective Decisions, *Photogrammetric Engineering and Remote Sensing*, 61(5): 539-547.
- Eastman, J.R., Kyem, P.A.K., y Toledano, J., 1993. A Procedure for Multi-Objective Decision Making in GIS Under Conditions of Competing Objectives, *Proceedings, EGIS'93*, 438-447.
- Eastman, J.R., Kyem, P.A.K., Toledano, J. y Jin, W., 1993. *GIS and Decision Making*, Explorations in Geographic Information System Technology, 4, UNITAR, Génova.
- FAO, 1976. *A Framework for Land Evaluation*, Soils Bulletin 32. Food and Agricultural Organization of the United Nations, Roma.
- Feiring, B.R., 1986. Linear Programming: An Introduction, *Quantitative Applications in the Social Sciences*, Vol. 60, Sage Publications, Londres.
- Honea, R.B., Hake, K.A., y Durfee, R.C., 1991. Incorporating GISs into Decision Support Systems: Where Have We Come From and Where Do We Need to Go? In: M. Heit and A. Shortreid (eds.), *GIS Applications in Natural Resources*. GIS World, Inc., Fort Collins, Colorado.
- Ignizio, J.P., 1985. Introduction to Linear Goal Programming, *Quantitative Applications in the Social Sciences*, Vol. 56, Sage Publications, Londres.
- Janssen, R. y Rietveld, P., 1990. Multicriteria Analysis and Geographical Information Systems: An Application to Agricultural Land Use in the Netherlands. In: H.J. Scholten y J.C.H. Stillwell, (eds.), *Geographical Information Systems for Urban and Regional Planning*: 129-139. Kluwer Academic Publishers, Dordrecht, Países Bajos.
- Rao, M., Sastry, S.V.C., Yadav, P.D., Kharod, K., Pathan, S.K., Dhinwa, P.S., Majumdar, K.L., Sampat Kumar, D., Patkar, V.N. y Phatak, V.K., 1991. *A Weighted Index Model for Urban Suitability Assessment—A GIS Approach*. Bombay Metropolitan Regional Development Authority, Bombay, India.

- Rosenthal, R.E., 1985. Concepts, Theory and Techniques: Principals of Multiobjective Optimization. *Decision Sciences*, 16(2): 133-152.
- Saaty, T.L., 1977. A Scaling Method for Priorities in Hierarchical Structures. *J. Math. Psychology*, 15: 234-281.
- Voogd, H., 1983. *Multicriteria Evaluation for Urban and Regional Planning*. Pion, Ltd., Londres.
- Wright, J., ReVelle, C. y Cohon, J., 1983. A Multiobjective Integer Programming Model for the Land Acquisition Problem. *Regional Science and Urban Economics*, 13: 31-53.
- Zadeh, L.A., 1965. Fuzzy Sets. *Information and Control*, 8: 338-353.

# CAPÍTULO 14 - Apoyo en la Toma de Decisiones: Manejo de la Incertidumbre

La incertidumbre es inevitable en el proceso de toma de decisiones. En la comunidad SIG, el tema de la incertidumbre ha recibido un considerable interés (ver Goodchild y Gopal, 1989), sin embargo, la atención se ha centrado particularmente en el error de medición: la expresión del error (Burrough, 1986; Lee y otros, 1987; Maling, 1989; Stoms, 1987), la evaluación del error (Congalton, 1991), la propagación del error (Burrough, 1986) y el informe de la calidad de los datos (Moellering y otros, 1988; Slonecker y Tosta, 1992). También ha habido un interés considerable en otras formas de incertidumbre como la expresada por los grupos difusos (Ej.: Fisher, 1992). No obstante, se ha prestado menos atención a cómo se combinan estas incertidumbres para afectar el proceso de toma de decisiones y el riesgo del mismo.

Como el campo se ha vuelto más competente en la comprensión y el manejo de la incertidumbre y su relación con el riesgo en la toma de decisiones, es inevitable en el SIG un movimiento que se aparta de las decisiones *duras* del SIG tradicional (donde se asume que las bases de datos y los modelos son perfectos) y se aproxima a los procedimientos dominados por las decisiones *blandas*. Con un conocimiento de las incertidumbres en la base de datos y en la regla de decisión, es posible cambiar los resultados duros booleanos de las decisiones del SIG tradicional en resultados probabilísticos blandos – no para hablar si un área tiene o no un problema con la erosión del suelo, sino de la *probabilidad* de que ésta tenga un problema con la erosión del suelo; no si un área es adecuada o no para la asignación de terreno, sino del grado en el cual es adecuada. Esto permitirá luego desarrollar una decisión dura final basada en el nivel de riesgo que uno está dispuesto a asumir. Entonces, por ejemplo, uno puede decidir enviar un equipo de extensión agrícola para visitar solo aquellos campos donde la probabilidad (o posibilidad) de un problema de erosión del suelo exceda el 70%.

El movimiento hacia las reglas de decisión blanda requerirá en parte el desarrollo de capacidades de manejo de la incertidumbre en SIG. Necesita estructuras de datos para transportar información sobre las incertidumbres y una revisión de las rutinas existentes para evaluar y divulgar la información sobre los errores. En IDRISI, se encuentra disponible una variedad de procedimientos para esta tarea.

## Tipología de la Incertidumbre

La incertidumbre incluye cualquier error conocido o desconocido, ambigüedad o variación en la base de datos y en la regla de decisión. Entonces, la incertidumbre se puede generar de elementos tales como el error de medición, la variabilidad inherente, la ambigüedad conceptual, la abstracción exagerada o la simple ignorancia de los parámetros importantes de modelo.

Considerar el proceso de la toma de decisiones como un problema de grupo de pertenencia es una perspectiva útil para entender la fuente y el rol de la incertidumbre en la toma de decisiones. Como se definió anteriormente, un *marco de decisión* contiene todas las alternativas (o hipótesis) bajo consideración, y la *evidencia* es la información a través de la cual puede evaluarse la pertenencia de una posición en el *grupo de decisión* (el grupo de las alternativas seleccionadas). Por lo tanto, el proceso de la toma de decisiones contiene tres elementos básicos dentro de los cuales puede ocurrir la incertidumbre – la evidencia, el grupo de decisión, y la relación que asocia estos dos.

## Incertidumbre en la Evidencia

Al examinar la evidencia para decidir qué elementos del grupo candidato pertenecen al grupo de alternativas para elegir (el grupo de decisión), uno evalúa las cualidades y características de esos elementos como están representadas en la base de datos. Sin embargo, existe una preocupación significativa aquí con el error de medición y cómo éste se propaga a través de una regla de decisión. Este tipo de incertidumbre usualmente se representa por medio de un error RMS (raíz media cuadrática) en el caso de datos cuantitativos o un error proporcional en el caso de datos cualitativos, y se basa en la teoría de probabilidad clásica y en la interferencia estadística para su evaluación y propagación.

## Incertidumbre en la Relación

El segundo elemento básico de una decisión es la especificación de la relación entre la evidencia y el grupo de decisión.

Aquí, la incertidumbre nace de al menos tres fuentes.

1. La primera se encuentra en los casos donde la *definición* de un criterio (en oposición a su medida) está sujeta a la incertidumbre. Los grupos con atributos claramente definidos se conocen como grupos *rígidos* y están sujetos a la lógica de los grupos clásicos. Entonces, por ejemplo, el grupo de áreas que serían inundadas por un aumento del nivel del mar está claramente definido. Sin tener en cuenta el error de medición, si un área es más baja que el nivel del mar proyectado, es sin ambigüedad alguna un miembro del grupo. Sin embargo, no todos los grupos están definidos tan claramente.

Considere, por ejemplo, el grupo de áreas con pendientes profundas. ¿Qué constituye una pendiente profunda? Si especificamos que una pendiente es profunda si tiene un gradiente del 10% o más, ¿significa esto que una pendiente de 9,9999999% no es profunda? Obviamente no existe un límite bien definido aquí. Dichos grupos se llaman grupos *difusos* (Zadeh, 1965) y son usualmente definidos por una función de pertenencia de grupo, como se verá más adelante. Aunque el reconocimiento del concepto de grupos difusos es relativamente nuevo en SIG, queda claro que dichos grupos son primordiales (si no dominantes) en las decisiones de asignación de terreno.

2. El segundo caso donde nace la incertidumbre es cuando la evidencia no implica directamente el grupo de decisión bajo consideración. En los ejemplos de las áreas inundadas y las pendientes profundas, hay una relación directa entre la evidencia y el grupo considerado. Sin embargo, también existen casos donde sólo se puede citar evidencia indirecta e imperfecta. Por ejemplo, podemos tener conocimiento de que los cuerpos de agua absorben la radiación infrarroja. Entonces podemos usar la evidencia de la reflectancia infrarroja baja en una imagen de sensor remoto como una declaración de la convicción en que el área está ocupada por aguas profundas abiertas. No obstante, esto es solo una creencia ya que otros materiales también absorben la radiación infrarroja.

Las declaraciones de creencia en el grado al cual la evidencia implica pertenencia de grupo son muy similares en carácter a las funciones de pertenencia a grupo difuso. Sin embargo, no son definiciones del grupo en sí, sino simples declaraciones del grado en el cual la evidencia sugiere la presencia del grupo (de cualquier manera definido). Por eso, la lógica de los grupos difusos no es apropiada aquí, en cambio, la teoría de *Bayes y Dempster-Shafer* sí se puede aplicar.

3. La tercer área donde puede ocurrir la incertidumbre al especificar la relación entre la evidencia y el grupo de decisión es comúnmente llamada *error de especificación de modelo* (Alonso, 1968). En algunos casos, las decisiones pueden estar basadas en un solo criterio, pero generalmente se requieren muchos criterios para definir el grupo de decisión. Entonces, por ejemplo, uno puede definir áreas adecuadas para el desarrollo como aquellas áreas con pendientes suaves y cercanas a los caminos. Aquí hay dos temas a considerar: ¿son estos criterios apropiados para definir áreas adecuadas; y, hemos agrupado correctamente la evidencia de estos criterios? Si la pertenencia de grupo indicada por las pendientes es 0,6 y la proximidad a los caminos es 0,7; ¿cuál es la pertenencia en el grupo de decisión? ¿Es el 0,42 de las probabilidades, el 0,6 de los grupos difusos, el 0,78 de Bayes, el 0,88 de Dempster-Shafer o el 0,65 de la combinación lineal? Es más, ¿con qué exactitud este valor agregado predice verdaderamente el grado en el cual la alternativa bajo consideración realmente pertenece al grupo de decisión? Claramente, la construcción de la regla de decisión puede tener un impacto enorme en el valor deducido de pertenencia de grupo.

## Incetidumbre en el Grupo de Decisión

La última área de interés con respecto a la incertidumbre en el proceso de toma de decisiones se ocupa del grupo final deducido. Como se dijo antes, el proceso de desarrollar el grupo de decisión consiste en convertir la evidencia para cada criterio en una declaración de grupo elemental, y luego agregar esas declaraciones en una sola producción que incorpora todos los criterios considerados. Claramente, aquí la incertidumbre es un agregado de las incertidumbres que se generaron al adquirir la evidencia y al especificar la relación entre esa evidencia y el grupo de decisión. No obstante, en la presencia de incertidumbre acerca del grado al cual cualquier candidato pertenece al grupo final (como resultado de la evidencia recolectada o sus implicaciones acerca de la pertenencia de grupo), se necesita alguna otra acción para desarrollar el grupo final. Se deberá establecer un umbral de incertidumbre para determinar qué alternativas serán juzgadas como pertenecientes al grupo de decisión. Hacer esto implica lógicamente alguna probabilidad de que la decisión tomada sea incorrecta – un concepto que puede describirse mejor como *riesgo de decisión*. Por ejemplo, con un grupo de posiciones para las cuales se evaluó la probabilidad de estar por debajo de un nuevo nivel del mar proyectado, la decisión final sobre cuáles de las posiciones finalmente se inundarán, será resuelta al establecer un umbral de probabilidad. Obviamente, este umbral se establece mejor en el contexto del riesgo de decisión.

En lo que resta de este capítulo, se explorará un juego de herramientas de IDRISI para el manejo de la incertidumbre que se genera en la evidencia (incertidumbre de la base de datos) y al especificar la relación entre esa evidencia y el

grupo de decisión (incertidumbre de la regla de decisión). Además, en cada una de estas dos secciones, se prestará atención al problema de emitir un juicio definitivo en el contexto de la incertidumbre y, por lo tanto, la solución del riesgo de decisión.

## Incetidumbre de la Base de Datos y Riesgo de la Decisión

Una evaluación del error de medición y un análisis de su propagación a través de los modelos de datos que combinan capas de datos diferentes son un aspecto esencial del manejo de la incertidumbre. En esta sección, examinaremos los procedimientos disponibles en IDRISI para la evaluación y propagación de errores, y muy importante, los procedimientos para evaluar los efectos de estos errores en el proceso de la toma de decisiones por medio de una consideración del riesgo de decisión.

### Evaluación de los Errores

La evaluación del error de medición normalmente se logra seleccionando una muestra de sitios para visitar en el terreno, remidiendo el atributo en esas posiciones por medio de algún instrumento más exacto, y luego, comparando las nuevas medidas con aquellas en la capa de datos. Para asistir este procedimiento, IDRISI provee los módulos SAMPLE y ERRMAT.

SAMPLE tiene la habilidad de establecer una muestra de puntos (en formato vectorial) según un esquema aleatorio, sistemático o aleatorio estratificado. Este último usualmente es el preferido ya que combina las mejores cualidades de los otros dos – el carácter imparcial del esquema aleatorio con la cobertura geográfica regular del esquema sistemático.

El tamaño de la muestra ( $n$ ) para ser usada se determina multiplicando una estimación del error estándar de la estadística de la evaluación. Esta es calculada con el cuadrado del valor estándar ( $z$ ) requerido para el nivel de confianza deseado (Ej.: 1,96 para una confianza del 95%) y dividiendo el resultado por el cuadrado del intervalo de confianza deseado ( $e$ ) (Ej.: 0,01 para  $\pm 10\%$ ). Para las estimaciones del tamaño de la muestra requerido para evaluar un error RMS, esta fórmula se simplifica en:

$$n = z^2 s^2 / 2e^2 \quad \text{donde } s \text{ es el RMS estimado.}$$

Para las estimaciones del error proporcional en los datos categóricos, la fórmula se transforma en:

$$n = z^2 pq / e^2 \quad \text{donde } p \text{ es el error proporcional estimado y } q = (1-p).$$

Tenga en cuenta que el término *estratificado* en el esquema aleatorio estratificado significa que está espacialmente estratificado de acuerdo a una división sistemática del área en regiones rectangulares. En los casos en los que se desea otra estratificación, y/o donde la región a ser muestreada no es de forma rectangular, se puede emplear el siguiente procedimiento:

1. Determine el área de la región estrato o irregular usando AREA y divídala por el área de toda la imagen. Esto indicará el área proporcional de la región estrato o irregular.
2. Divida el tamaño de muestra deseado por el área proporcional. Esto indicará un nuevo (y mayor) tamaño de muestra que será requerido para asegurar que el número deseado de puntos de muestra estará dentro del área de interés.
3. Ejecute el SAMPLE con el nuevo tamaño de muestra y use sólo aquellos puntos que se encuentran dentro del área de interés.

Una vez que se ha llevado a cabo la verdad de terreno en los puntos de muestra, se puede evaluar el error característico.

En el caso de evaluar datos cuantitativos por medio del RMS, se puede emplear la fórmula estándar para el RMS derivado de una muestra:

$$RMS = \sqrt{\frac{\sum (x_i - t)^2}{n - 1}}$$

Donde

$x_i$  = una medida

$t$  = valor verdadero



Sin embargo, en el caso de datos cualitativos, se debe usar una matriz de errores para evaluar la relación entre las categorías mapeadas y los valores verdaderos. Para facilitar este proceso, puede emplearse el módulo ERRMAT. Éste necesita dos archivos de entrada: la imagen original categórica (Ej.: un mapa del uso del suelo) y una segunda imagen con las categorías verdaderas. Este mapa *verdadero* generalmente se presenta en la forma de un mapa dominado por ceros (el fondo) con celdas aisladas que indican las posiciones de los puntos de muestra con sus valores verdaderos. Al usar estos datos, el ERRMAT produce una matriz de errores y estadísticas de resumen.

La matriz de errores producida por ERRMAT contiene una tabulación del número de puntos de muestra hallados en cada combinación posible de categorías verdaderas y mapeadas. La Figura 14-1 ilustra la salida básica de la matriz de errores. Como se puede ver, las tabulaciones a lo largo de la diagonal representan casos donde la categoría mapeada coincide con el valor verdadero. Las tabulaciones fuera de la diagonal representan errores y son tabuladas como totales en los márgenes. Los marginales de error representan el error proporcional por categoría, y el error proporcional total aparece en el extremo inferior derecho de la imagen. Los errores proporcionales en la parte inferior del gráfico se llaman *errores de omisión*, mientras que aquellos en el borde derecho se llaman *errores de comisión*. El primero representa los casos donde los puntos de muestra de una categoría en particular fueron mapeados como algo diferente, mientras que el segundo incluye casos donde las posiciones mapeadas como una categoría en particular son realmente algo diferente. El análisis cuidadoso de estos datos permite no sólo evaluar la cantidad de errores, sino también estipular de dónde ocurren y cómo pueden ser solucionados. Por ejemplo, es común ver los errores de omisión como una base para juzgar la adecuación del mapeo, y los errores de comisión, como un medio para determinar cómo fijar el mapa para incrementar la exactitud.

Verdadero						
	Coníferas	Mixtas	Caducifolias	Agua	Total	error
Coníferas	24	0	0	3	27	0,1 1
Mixtas	3	36	16	0	55	0,3 5
Caducifolias	0	0	28	0	28	0,0 0
Agua	2	0	0	14	16	0,1 2
Total	29	36	44	17	126	
error	0,17	0,00	0,36	0,1 8		0,1 9

Errores de omisión

**Figura 14-1.** Una Matriz de Errores.

Además de la matriz de errores básica, el ERRMAT también informa sobre los valores totales y por categoría del Índice Kappa de Acuerdo (KIA). El Índice Kappa de Acuerdo es similar a una cifra de exactitud proporcional (y por ello el complemento del error proporcional), excepto que este se ajusta al acuerdo casual.

## Propagación de los Errores

Cuando existe la incertidumbre en las capas de datos, ese error se propaga a través de cualquier análisis y se combina con el error de otras fuentes. Existen fórmulas específicas para la propagación de errores esperada generada de las operaciones matemáticas típicas de SIG (como las incluidas en SCALAR y OVERLAY). El **Apéndice 1** contiene un grupo representativo de dichas fórmulas. Además, IDRISI contiene dos módulos que, bajo ciertas circunstancias, propagan información de error automáticamente usando tales procedimientos. El primero es el módulo MCE descrito antes en este capítulo, mientras que el segundo es el SURFACE.

Si todos los factores de entrada que se presentan en el MCE contienen información de error (RMS) en el campo *error de valor* de sus archivos de documentación, el MCE determina el error de salida propagado y lo coloca en el archivo de documentación del resultado. Sin embargo, tenga en cuenta que esto implica dos *grandes* suposiciones – primero, no hay correlación entre los factores, y segundo, no hay incertidumbre en los pesos ya que esa incertidumbre ha sido resuelta al derivar un consenso. Si estas suposiciones no son válidas, se debe derivar un nuevo resultado usando un procedimiento Monte Carlo como se describe más adelante.

En el caso de SURFACE, la información de error también se propaga cuando se derivan pendientes de un modelo de

elevación digital donde el error RMS ha sido ingresado en el campo *error de valor* de su archivo de documentación.

A pesar de la disponibilidad de las fórmulas de propagación, generalmente es difícil aplicar este enfoque a la propagación de errores porque:

1. La propagación está fuertemente afectada por la intercorrelación entre las variables y la correlación no siempre se conoce al principio;
2. Sólo un número limitado de fórmulas se encuentra disponible actualmente, y muchas operaciones SIG poseen características de propagación desconocidas.

Como resultado, hemos incorporado en IDRISI las herramientas para un punto de vista más general llamado *Simulación de Monte Carlo*.

## Simulación de Monte Carlo

En el análisis de la propagación de errores a través de la Simulación de Monte Carlo, simulamos los efectos del error en cada una de las capas de datos para estimar cómo se propaga a través del análisis. En la práctica, el análisis se ejecuta dos veces – primero en el modo normal, y luego, una segunda vez usando capas de datos que contienen el error simulado. Al comparar los dos resultados, los efectos de los errores se pueden calcular – la única razón por la cual difieren es debido al error introducido. Por lo general, HISTO se usa para examinar la distribución de estos errores como se ilustran en una imagen de diferencia producida con OVERLAY. Con un resultado normalmente distribuido, la desviación estándar de esta imagen de diferencia puede usarse como un buen indicador del RMS final.<sup>60</sup>


La herramienta utilizada para introducir el error simulado es RANDOM. Ésta crea imágenes con valores aleatorios de acuerdo a cualquiera de los modelos rectilíneos, normales o lognormales. Para la distribución normal y lognormal, el error RMS puede ser un solo valor uniforme para toda la imagen, o puede estar definido por una imagen que posee valores variados espacialmente. Para los datos categóricos, el modelo rectilíneo produce valores enteros que pueden emplearse como códigos de categorías. Para los datos cuantitativos, todos los modelos pueden generar números reales. Por ejemplo, para agregar un error simulado a un modelo de elevación digital con un error RMS de 3 metros, se usa RANDOM para crear una superficie empleando un modelo normal con una media de 0 y una desviación estándar de 3. Esta imagen luego se *agrega* al modelo de elevación digital. Observe que el resultado no está hecho para tener ningún parecido con la realidad – sólo contiene un error de la misma naturaleza como el que se cree que existe en el original.

## Incertidumbre de la Base de Datos y Riesgo de Decisión

Dada una estimación del error de medición y un análisis de cómo se ha propagado a través de la regla de decisión, el módulo PCLASS puede usarse para determinar una decisión final con el completo reconocimiento del riesgo de decisión que presentan estas incertidumbres. PCLASS evalúa la probabilidad de que el valor de los datos en cualquier celda raster exceda o sea excedido por un umbral específico. PCLASS asume un modelo aleatorio del error de medición, caracterizado por una declaración de error de Raíz Media Cuadrática (RMS). En el sistema IDRISI, el metadato para cada imagen raster contiene un campo donde se puede establecer el error en los valores de atributo, como un RMS para datos cuantitativos, o bien como un error proporcional para datos cuantitativos. El PCLASS usa el RMS registrado para una imagen cuantitativa para evaluar la probabilidad de que cada valor en la imagen se encuentre arriba o debajo de un umbral especificado. Esto lo realiza midiendo el área delineada por ese umbral bajo una curva normal con una desviación estándar igual al RMS (Figura 14-2). El resultado es un mapa de probabilidad como el que se ilustra en la Figura 14-3, y que expresa la probabilidad de que cada área pertenezca al grupo de decisión.


---

<sup>60</sup> La Simulación de Monte Carlo se basa en el uso de un grupo muy grande de simulaciones para derivar sus caracterizaciones. En los casos donde cada celda provee una nueva simulación, el compuesto total de celdas puede brindar un ejemplo tan grande. Los resultados son mejorados por medio de la ejecución repetida de tal análisis y de un promedio de los resultados.



**Figura 14-2**


Con el PCLASS tenemos el equivalente *blando* de una operación RECLASS *dura*. Por ejemplo, considere el caso de hallar áreas que serán inundadas por un aumento en el nivel del mar como resultado del calentamiento global. Tradicionalmente, esto se evaluaría reclasificando las alturas en dos grupos en un modelo de elevación digital – aquellas debajo del nivel del mar proyectado y aquellas encima de éste. Con PCLASS, en cambio, se reconoce el error inherente en la medición de las alturas para que el mapa producido no sea un mapa booleano duro de ceros y unos, sino un mapa de probabilidad blando que varía continuamente de cero a uno. La Figura 14-3, por ejemplo, ilustra la producción de PCLASS después de evaluar la probabilidad de que las alturas sean menores al nuevo nivel del mar proyectado de 1,9 metros encima del nivel actual en Boston Harbor, EE.UU. Con este mapa de probabilidad continua, se puede tomar una decisión final al reclasificar el mapa de probabilidad de acuerdo al nivel de riesgo de decisión que uno desea asumir. Las Figuras 14-4 y 14-5, por ejemplo, muestran la diferencia entre la línea de la costa original y aquella asociada con el nuevo nivel del mar, mientras que acepta sólo una probabilidad del 5% de equivocación en comparación con una probabilidad del 25%. Claramente, el Modelo de Elevación Digital (DEM) usado en la evaluación no es muy preciso. No obstante, esto ilustra el hecho de que hasta los datos pobres pueden usarse efectivamente si sabemos cuán pobres son.



**Figura 14-3.** Probabilidad de ser inundado.



**Figura 14-4.** Zona de inundación con 5% de riesgo.



**Figura 14-5.** Zona de inundación con 25% de riesgo.

## Incertidumbre de la Regla de Decisión

En la *Tipología de la Incertidumbre* presentada anteriormente, el segundo elemento más importante identificado (después del error de medición) fue el que especifica la relación entre la evidencia y el grupo de decisión final – un aspecto que puede llamarse *incertidumbre de la regla de decisión*. Esta es un área donde se requiere mucha más investigación. Sin embargo, el sistema IDRISI incluye un extenso juego de herramientas para facilitar la evaluación y propagación (o agregado en este contexto) de esta forma de incertidumbre.

Todas estas herramientas se ocupan de la incertidumbre inherente en establecer si una entidad pertenece al grupo final de decisión y, por lo tanto, se encuentra en una categoría general de expresión de pertenencia a grupo incierto,

conocido como una *medida difusa*. El término *medida difusa* (no debe confundirse con la instancia más específica de un Grupo Difuso) se refiere a cualquier función de grupo que sea monótonica con respecto a la pertenencia de grupo (Dubois y Prade, 1982). Los ejemplos importantes de medidas difusas incluyen *probabilidades* Bayesianas, las *creencias* y *plausibilidades* de la teoría Dempster-Shafer y las *posibilidades* de los Grupos Difusos.

Un rasgo común de las medidas difusas es que éstas siguen la Ley DeMorgan en la construcción de los operadores de intersección y unión (Bonissone y Decker, 1986), y por lo tanto, también las reglas básicas de propagación de la incertidumbre en el agregado de evidencia. La Ley DeMorgan establece una relación triangular entre los operadores de intersección, unión y negación de manera que:

$$\begin{aligned} T(a, b) &= \sim S(\sim a, \sim b) \\ \text{donde } T &= \text{Intersección (AND)} = T\text{-Norma} \\ y \quad S &= \text{Unión (OR)} = T\text{-CoNorma} \\ y \quad \sim &= \text{Negación (NOT)} \end{aligned}$$

Los operadores de intersección en este contexto se conocen como *normas triangulares*, o simplemente *T-Normas*, mientras que los operadores de unión se conocen como *co-normas triangulares* o *T-CoNormas*.

Una T-Norma puede ser definida como (Yager, 1988):

$$\begin{aligned} \text{Un mapeo } T: [0,1] * [0,1] \rightarrow [0,1] \text{ de manera tal que:} \\ T(a, b) &= T(b, a) && (\text{conmutativo}) \\ T(a, b) &\geq T(c, d) \text{ si } a \geq c \text{ y } b \geq d && (\text{monotónico}) \\ T(a, T(b, c)) &= T(T(a, b), c) && (\text{asociativo}) \\ T(1, a) &= a \end{aligned}$$

Algunos ejemplos de T-Norma incluyen:

$$\begin{aligned} \min(a, b) &&& (\text{el operador de intersección de grupos difusos}) \\ a * b &&& (\text{el operador de intersección de probabilidades}) \\ 1 - \min(1, ((1-a)^p + (1-b)^p)(1/p)) &&& (\text{para } p \geq 1) \\ \max(0, a+b-1) \end{aligned}$$

Por el contrario, una T-CoNorma es definida como:  
un mapeo  $S: [0,1] * [0,1] \rightarrow [0,1]$  de manera tal que:

$$\begin{aligned} S(a, b) &= S(b, a) && (\text{conmutativo}) \\ S(a, b) \geq S(c, d) \text{ si } a \geq c \text{ and } b \geq d &&& (\text{monotónico}) \\ S(a, S(b, c)) &= S(S(a, b), c) && (\text{asociativo}) \\ S(0, a) &= a \end{aligned}$$

Algunos ejemplos de T-CoNorma incluyen:

$$\begin{aligned} \max(a, b) &&& (\text{el operador de unión de grupos difusos}) \\ a + b - a * b &&& (\text{el operador de unión de probabilidades}) \\ \min(1, (a^p + b^p)(1/p)) &&& (\text{para } p \geq 1) \\ \min(1, a+b) \end{aligned}$$

Estos ejemplos muestran que un rango bastante amplio de operaciones se encuentra disponible para el agregado de medidas difusas, y también, para el agregado de criterios en el proceso de la toma de decisiones. Entre los diferentes operadores, los más extremos (en el sentido que producen los resultados numéricos más extremos en el agregado) son el operador T-Norma *mínima* y el operador T-CoNorma *máxima*. Estos operadores además tienen un significado espacial ya que son los operadores de agregado más comúnmente empleados para los grupos difusos. Es más, Yager (1988) ha demostrado que éstos representan los extremos finales de un rango de operadores de agregado relacionados que pueden ser producidos a través de la ejecución de un Porcentaje Ponderado Ordenado. Como se indicó en el capítulo **Apoyo en la Toma de Decisiones: Análisis de la Estrategia de Decisión**, este rango también incluye el operador tradicional Combinación Lineal Ponderada, comúnmente utilizado en SIG. Sin embargo, el tema importante aquí no es que una familia de operadores de agrupamiento en particular sea correcta o mejor que otra, sino simplemente que diferentes expresiones de la incertidumbre de la regla de decisión requieren diferentes procedimientos de agrupamiento.

Actualmente, hay tres lógicas principales en uso para la expresión de la incertidumbre de la regla de decisión, todas representadas en el juego de módulos de IDRISI: teoría del Grupo Difuso, estadísticas Bayesianas y teoría Dempster-Shafer. Cada una es distinta y posee su propio grupo diferente de operadores T-Norma/T-CoNorma. No obstante, el contexto en el cual uno emplea una en oposición a otra no es siempre claro. En parte, esto resulta del hecho de que las reglas de decisión incluyen más de una forma de incertidumbre. Por otro lado, esto también sucede por falta de investigación dentro del campo SIG en el contexto en el cual debe usarse cada una. Dicho esto, aquí hay algunas guías que pueden utilizarse:

- Los problemas de decisión que pueden ubicarse en un marco de mapa de adecuación pueden ser tratados con la lógica de Grupos Difusos. Este procedimiento ha sido presentado en detalle en la sección sobre Evaluación Multicriterio del capítulo **Apoyo en la Toma de Decisiones: Análisis de la Estrategia de Decisión**. Por ejemplo, si definimos la adecuación en términos de un grupo de factores continuos (distancia a los caminos, pendiente, etc.), la expresión de adecuación es continua. No hay una separación clara entre las áreas que son adecuadas y aquellas que no lo son. Muchos (si no la mayoría) de los problemas de asignación de recursos en SIG se encuentran en esta categoría y, por lo tanto, pertenecen al campo de los Grupos Difusos.

- La presencia de la *borrosidad*, en el sentido de ambigüedad, no siempre implica que el problema se encuentra en el campo de los Grupos Difusos. Por ejemplo, la incertidumbre de la medición asociada con un grupo rígido puede llevar a una función de pertenencia de grupo que es esencialmente idéntica en carácter a la de un Grupo Difuso. Más aún, la característica distintiva de un grupo difuso es que el grupo es inherentemente ambiguo. Por ejemplo, si uno considera el caso de decidir si un área se inundará como resultado de la construcción de una represa, existirá alguna incertidumbre debido al error en el modelo de elevación. Si uno asume un modelo de error aleatorio y una independencia espacial de errores, entonces el gráfico de la probabilidad de inundación teniendo en cuenta la altura registrada en la base de datos tomará el aspecto de una curva cumulativa en forma de S, muy similar a la función de pertenencia típica a un grupo difuso. Sin embargo, el grupo en sí no es ambiguo – sino rígido. La medida de la elevación es la que está en duda.

- La presencia de la *borrosidad*, en el sentido de la falta de conclusión, generalmente se encuentra en el campo de la teoría de probabilidad Bayesiana o su variante conocida como la teoría Dempster-Shafer. El problema aquí es el de la evidencia indirecta – la evidencia a mano no permite evaluar directamente la pertenencia de grupo, sino inferirla con algún grado de incertidumbre. En su forma prototípica, sin embargo, ambas lógicas se ocupan de la substanciación de los grupos rígidos – es la fuerza de la relación entre la evidencia y el grupo de decisión lo que está en duda. Un ejemplo clásico aquí es el caso del procedimiento de clasificación supervisada en el análisis de imágenes tomadas por sensores remotos. Al usar datos de sitios de entrenamiento, un clasificador Bayesiano (es decir, motor de decisión) establece una relación estadística entre la evidencia y el grupo de decisión (en la forma de una función de densidad de probabilidad condicional). Es esta relación establecida, pero incierta, la que permite inferir el grado de pertenencia de un pixel al grupo de decisión.


- A pesar de su herencia común, el agregado de evidencia usando Bayes y Dempster-Shafer puede generar resultados bastante diferentes. La diferencia principal entre los dos está caracterizada por el rol de la ausencia de evidencia. Bayes considera la ausencia de evidencia como apoyo a una hipótesis particular para luego constituir evidencia como apoyo a hipótesis alternativas, mientras que Dempster-Shafer no lo hace. Entonces, a pesar del hecho de que ambas consideran las hipótesis en el marco de decisión como exhaustivas, Dempster-Shafer reconoce el concepto de la ignorancia, mientras que Bayes no lo hace. Otra diferencia es que el enfoque Bayesiano combina la evidencia condicionada por la hipótesis en el grupo de decisión (es decir, se basa en datos de entrenamiento), mientras que la teoría Dempster-Shafer agrega evidencia derivada de fuentes independientes.

Más allá de estas extensas guías, la implementación completa de estas lógicas es a menudo difícil porque su desarrollo teórico ha sido restringido a contextos prototípicos. Por ejemplo, la teoría del Grupo Difuso expresa

ambigüedad en la pertenencia de grupo en la forma de una función de pertenencia. Sin embargo, no trata el problema de la incertidumbre en la forma de la función de pertenencia en sí. ¿Cómo, por ejemplo, se agrega evidencia en el contexto de la evidencia indirecta y un grupo de decisión ambiguo? Claramente, hay mucho por aprender aquí. Para empezar, la siguiente sección comienza tratando los temas para cada una de estas formas principales para la expresión de la incertidumbre.

## Grupos Difusos


Los Grupos Difusos son grupos (o clases) sin límites bien marcados; es decir, la transición entre la pertenencia y la no pertenencia de una posición en el grupo es gradual (Zadeh, 1965; Schmucker, 1982). Un Grupo Difuso se caracteriza por un grado de pertenencia difusa (también llamado *posibilidad*) que oscila de 0,0 a 1,0, indicando un aumento continuo de la no pertenencia a la pertenencia completa. Por ejemplo, al evaluar si una pendiente es profunda, podemos definir una función de pertenencia difusa de manera tal que una pendiente de 10% tenga una pertenencia de 0, y una pendiente de 25% tenga una pertenencia de 1,0. Entre el 10% y el 25%, la pertenencia difusa de una pendiente aumenta gradualmente en la escala de 0 a 1 (Figura 14-6). Esto contrasta con el grupo rígido clásico, el cual posee límites distintivos. No obstante, un grupo rígido también puede interpretarse como un caso especial de grupo difuso en el cual la pertenencia difusa cambia instantáneamente de 0 a 1.



**Figura 14-6.** Función de pertenencia a un grupo difuso vs. Rígido.

La teoría del Grupo Difuso brinda una rica base matemática para entender problemas de decisión y para construir reglas de decisión en la evaluación y combinación de criterios. En uso, el módulo FUZZY de IDRISI está diseñado para la construcción de funciones de pertenencia a Grupo Difuso, mientras que la opción OWA del módulo MCE ofrece un rango de operadores de agregado apropiado. FUZZY brinda cuatro tipos de función de pertenencia:

1. **Sigmoide:** La función de pertenencia *sigmoide* (“en forma de s”) es tal vez la más comúnmente usada en la teoría de Grupo Difuso. Aquí se produce usando una función coseno como se describe en el Sistema de Ayuda on-line. En uso, FUZZY requiere las posiciones (del eje X) de 4 *puntos de inflexión* que gobiernan la forma de la curva. Éstos se indican en la Figura 14-7 como a, b, c y d, y representan los puntos de inflexión cuando la función de pertenencia aumenta por encima de 0, se acerca a 1, disminuye por debajo de 1 nuevamente, y finalmente se acerca a 0. La función en el extremo derecho de la Figura 14-7 muestra los cuatro puntos de inflexión como diferentes. Sin embargo, esta misma función puede tomar formas diferentes. La Figura 14-7 ilustra todas las posibilidades. Comenzando por la izquierda, la forma de la función *monotónicamente creciente* se eleva de 0 a 1 y nunca disminuye. El concepto previamente mencionado de las pendientes profundas es un buen ejemplo donde el primer punto de inflexión *a* es de 10%, y el segundo *b* es de 25%. Como nunca vuelve a disminuir, los puntos de inflexión *c* y *d* tienen el mismo valor que *b* (FUZZY entiende esta convención). No obstante, la interfase FUZZY en este caso facilita la entrada de datos solicitando los valores sólo para los puntos de inflexión *a* y *b*. La segunda curva de la Figura 14-7 muestra una función *monotónicamente decreciente* que comienza en 1, luego disminuye y permanece en 0. En este caso en que la función de pertenencia comienza en 1 y luego disminuye a 0 pero nunca crece, *a* y *b* tienen valores idénticos a *c* (el punto en el cual comienza a disminuir), y *d* tiene el valor del punto en el cual llega a 0. La interfase FUZZY sólo necesita los puntos de inflexión *c* y *d* para este tipo de función. Las últimas dos funciones que aparecen en la Figura son llamadas *simétricas* porque crecen y luego vuelven a disminuir. En el caso en que la función crece y luego disminuye inmediatamente (la tercera curva en la Figura 14-7), los puntos *b* y *c* adquieren los mismos valores. Finalmente, donde crece, permanece en 1 por un momento, y luego disminuye, los cuatro valores son distintos. En ambos casos, la interfase FUZZY necesita la entrada de los cuatro puntos de inflexión. Tenga en cuenta que no se requiere ninguna simetría geométrica para las funciones simétricas, sólo que la curva se eleve y luego vuelva a caer. Es muy probable que la forma de la curva entre *a* y *b* y la de *c* y *d* sea diferente, como se ilustra en la curva del extremo derecho en la Figura 14-7.




**Figura 14-7.** Función de membresía sigmoideal.

2. **En Forma de J:** La función en Forma de J también es bastante común, aunque en la mayoría de los casos parece que la función sigmoide es mejor. La Figura 14-8 muestra las diferentes posibilidades de las funciones en Forma de J y las posiciones de los puntos de inflexión. Debe tenerse en cuenta que con la función en Forma de J, la función se acerca a 0 pero sólo lo alcanza en el infinito. Por ello, los puntos de inflexión *a* y *d* indican los puntos en los cuales la función llega a 0,5 en lugar de 0.




**Figura 14-8.** Función de membresía en forma J.

3. **Lineal:** La Figura 14-9 muestra la función Lineal y sus variantes, junto con la posición de los puntos de inflexión. Esta función se usa extensivamente en aparatos electrónicos que dan a conocer la lógica de grupo difuso, en parte debido a su simplicidad, pero también en parte debido a la necesidad de monitorear la producción de los sensores esencialmente lineales.



**Figura 14-9.** Función de membresía lineal.

4. **Definida por el Usuario:** Cuando la relación entre el valor y la pertenencia difusa no sigue ninguna de las tres funciones mostradas anteriormente, la función definida por el usuario es la más aplicable. Un número ilimitado de puntos de control pueden usarse en esta función para definir la curva de pertenencia difusa. La pertenencia difusa entre dos puntos de control cualquiera es interpolada linealmente, como en la Figura 14-10.



**Figura 14-10.** Función de membresía definida por el usuario.

En la Evaluación Multicriterio, la pertenencia a grupo difuso se usa en la estandarización de criterios. Exactamente qué función debe usarse depende del entendimiento de la relación entre el criterio y el grupo de decisión, y en la disponibilidad de información para inferir la pertenencia difusa. En la mayoría de los casos, la función sigmoide o bien la lineal serán suficientes.

## Teoría de la Probabilidad Bayesiana

Cuando la información completa está disponible o se supone, la herramienta principal para la evaluación de la relación entre la evidencia indirecta y el grupo de decisión es la teoría de la Probabilidad Bayesiana. Ésta es una extensión de la teoría de la Probabilidad Clásica que nos permite combinar nueva *evidencia* acerca de una hipótesis junto con conocimiento previo para llegar a una estimación de la probabilidad de que la hipótesis sea verdadera. La base de esto es el Teorema de Bayes que establece que (en la nota de la teoría de la probabilidad):

donde:

$$p(h|e) = \frac{p(e|h) \cdot p(h)}{\sum_i p(e|h_i) \cdot p(h_i)}$$

$p(h|e)$  = la probabilidad de la hipótesis como verdadera dada la evidencia (probabilidad posterior)

$p(e|h)$  = la probabilidad de encontrar esa evidencia en el caso que la hipótesis sea verdadera

$p(h)$  = la probabilidad de la hipótesis como verdadera sin importar la evidencia (probabilidad previa)

Para aquellos que no estén familiarizados con la teoría de la probabilidad, esta fórmula puede parecer intimidatoria. Sin embargo, en realidad es bastante simple. El caso más simple es cuando solo tenemos dos hipótesis para elegir – una hipótesis  $h$  y su complemento  $\sim h$  (que  $h$  **no** es verdadera), las probabilidades de éstas son representadas por  $p(h)$  y  $p(\sim h)$ , respectivamente. Por ejemplo, ¿un área se inundará o no? La primera pregunta para considerar es si tenemos algún conocimiento previo que nos lleve a la probabilidad de que una o la otra posibilidad sea verdadera. Esto se llama una *probabilidad a priori*. Si no tenemos ningún conocimiento, entonces se supone que las hipótesis son igualmente probables.

El término  $p(e|h)$  expresa la probabilidad de que encontremos la evidencia que tenemos si la hipótesis en cuestión fuese verdadera. Esto se conoce como una probabilidad *condicional*, y se evalúa en base al hallazgo de áreas en donde sabemos que la hipótesis es verdadera y a la recolección de datos para evaluar la probabilidad de que la evidencia que tenemos es consistente con la hipótesis. Nos referiremos a esto como datos de verdad de terreno aunque se puede evaluar con respaldo teórico o por medio de la simulación.

El término  $p(h|e)$  es una probabilidad *posterior* creada después del conocimiento y evidencia previa porque las hipótesis se combinan. Al incorporar información extra acerca de la hipótesis, la probabilidad para cada hipótesis es modificada para reflejar la nueva información. El Teorema de Bayes supone que la información completa se puede lograr, y por ello, la única razón para que no tengamos una evaluación exacta de la probabilidad es la falta de evidencia. Al agregar más evidencia al conocimiento previo, en teoría uno podría alcanzar una evaluación de la probabilidad verdadera para todas las hipótesis.

## Teoría de Dempster-Shafer

La teoría de Dempster-Shafer, una extensión de la teoría de la probabilidad Bayesiana, da lugar a la expresión de la ignorancia en el manejo de la incertidumbre (Gordon y Shortliffe, 1985; Lee y otros, 1987). Las suposiciones básicas de la teoría de Dempster-Shafer son el hecho de que la ignorancia existe en el cuerpo de conocimiento, y que la convicción en una hipótesis no necesariamente es el complemento de la convicción en su negación.

Primero, la teoría de Dempster-Shafer define las hipótesis en una estructura jerárquica (Figura 14-11) desarrollada a partir de un grupo básico de hipótesis que forman el *marco de discernimiento*.<sup>61</sup> Por ejemplo, si el marco de


---

<sup>61</sup> El *marco de discernimiento* en la teoría Dempster-Shafer tiene esencialmente el mismo significado que el término *marco de decisión* usado en este documento – es decir, el grupo de hipótesis o clases alternativas que pueden ser substanciadas o asignadas a entidades. Dempster-Shafer considera estas hipótesis como exhaustivas. Entonces, las declaraciones de apoyo para cualquier combinación jerárquica de clases representan un grado de inhabilidad para comprometerse a una de las hipótesis simples en el marco de discernimiento. Sin embargo, en la práctica, Dempster-Shafer trata estas combinaciones jerárquicas como hipótesis adicionales. Además, en el contexto de SIG y Teledetección, pueden existir buenas razones para tratar un compromiso sin solución con una de estas combinaciones jerárquicas como evidencia verdadera de una clase/hipótesis independiente a la cual se pueden asignar entidades. Por ejemplo, con un marco de discernimiento que incluye [bosque] y [pantano], la presencia de compromiso con una combinación [bosque pantano] puede representar en realidad la presencia de una clase de “pantano boscoso” que no puede resolverse consiguiendo una mejor evidencia. Como resultado, aquí reconocemos que el analista puede considerar que el marco de decisión contenga todas las combinaciones que forma el marco de discernimiento de Dempster-Shafer. Esto no quebranta la lógica de Dempster-Shafer, ya que simplemente estamos emitiendo un juicio post-análisis de que ciertas combinaciones representan clases nuevas y, por lo tanto, pueden formar un grupo de decisión.



discernimiento incluye tres hipótesis básicas: {A, B, C}, la estructura de hipótesis para la cual Dempster-Shafer acepta evidencia, incluye todas las combinaciones posibles, [A], [B], [C], [A, B], [A, C], [B, C] y [A, B, C]. Las tres primeras se llaman hipótesis simples porque cada una contiene solo un elemento básico. El resto son hipótesis compuestas que contienen más de un elemento básico. Dempster-Shafer reconoce estas combinaciones jerárquicas porque a menudo ocurre que la evidencia que tenemos apoya algunas combinaciones de hipótesis sin la capacidad para distinguir además los subgrupos. Por ejemplo, podemos incluir clases de [caducifolias] y [coníferas] en una clasificación de la cobertura terrestre, y encontramos que la evidencia de una fotografía aérea en blanco y negro puede distinguir áreas forestadas de aquellas no forestadas, pero no el tipo de forestación. En este caso podemos usar la evidencia como apoyo a la combinación jerárquica [caducifolias, coníferas]. Claramente, esto representa una declaración de incertidumbre. Sin embargo, además provee información valiosa que será usada en ventaja por el procedimiento Dempster-Shafer en cualquier declaración de creencia acerca de estas hipótesis.

Al expresar compromiso con cualquiera de estas hipótesis, la teoría Dempster-Shafer reconoce seis conceptos importantes: *asignación de probabilidad básica* (BPA), *ignorancia*, *creencia*, *descreimiento*, *posibilidad* e *intervalo de creencia*.



**Figura 14-11.** Estructura jerarquizada de subconjuntos en el conjunto total [A,B,C].

Una asignación de probabilidad básica (BPA) representa el apoyo que una pieza de evidencia provea una de estas hipótesis y no a sus propios subgrupos. Por ello, una BPA para [A, B] representa la masa de apoyo para [A, B], pero no para [A] o [B] – es decir, el grado de apoyo para alguna combinación indistinguible de [A] y [B]. Esto se simboliza usualmente con la letra “m” (de masa), Ej.:

$$m(A,B) = \text{asignación de probabilidad básica para } [A, B]$$

La asignación de probabilidad básica para una hipótesis dada puede derivarse de un juicio subjetivo o de datos empíricos. Debido a que una BPA es una medida difusa, el módulo FUZZY también puede ser usado en IDRISI para desarrollar una BPA a partir de un grupo de datos dado.

La suma de todas las BPA será en todo momento igual a 1,0. Entonces, la BPA para el último supergrupo ([A, B, C] en este ejemplo) será igual al complemento de la suma de todas las otras BPA. Esta cantidad representa, por lo tanto, la *ignorancia* – la inhabilidad para comprometerse con ningún grado de diferenciación entre los elementos del marco de discernimiento.

La *creencia* representa el apoyo total a una hipótesis, y se extrae de las BPA para todos los subgrupos de esa hipótesis, es decir:

$$BEL(X) = \sum m(Y) \quad \text{cuando } Y \subseteq X$$

Entonces la convicción en [A, B] será calculada como la suma de las BPA para [A, B], [A] y [B]. En este ejemplo, la convicción representa la probabilidad de que una entidad sea A o B. Observe que en el caso de las hipótesis simples, la asignación de probabilidad básica y la convicción son idénticas.

En contraste con la convicción, la *posibilidad* representa el grado en el cual una hipótesis no puede ser descreída. A diferencia del caso de la teoría de la probabilidad Bayesiana, el *descreimiento* no es automáticamente el complemento de la convicción, sino que representa el grado de apoyo a todas las hipótesis que no se interceptan con esa hipótesis. Entonces:

$$\begin{aligned} \text{entonces } PL(X) &= 1 - BEL(\bar{X}) & \text{cuando } \bar{X} &= \text{no } X \\ PL(X) &= \sum m(Y) & \text{cuando } Y \cap X &\neq \emptyset \end{aligned}$$

Al interpretar estos conceptos, podemos decir que mientras la convicción representa el grado de evidencia dura en apoyo a una hipótesis, la posibilidad indica el grado en el cual las condiciones *perecen correctas* para esa hipótesis, aún cuando no hay evidencia dura. Para cada hipótesis, entonces, la convicción es el límite inferior de nuestro compromiso con esa hipótesis, y la posibilidad representa el límite superior. El rango entre las dos se llama *intervalo de creencia*, y representa el grado de incertidumbre al establecer la presencia o ausencia de esa hipótesis. Como resultado, las áreas con un intervalo de creencia alto son aquellas en las cuales la evidencia nueva suministra el mayor grado de información. Dempster-Shafer es muy útil para establecer el valor de la información y para diseñar una estrategia de recolección de datos mayormente efectiva para reducir la incertidumbre.

Comparada con la teoría de la probabilidad Bayesiana, la teoría Dempster-Shafer parece más apta para manejar la incertidumbre que incluye ignorancia. En la teoría de la probabilidad Bayesiana, sólo las hipótesis simples son reconocidas, y se supone que son exhaustivas (es decir, deben sumar 1,0). Entonces, la ignorancia no es reconocida, y la falta de evidencia para una hipótesis constituye evidencia en contra de esa hipótesis. Estos requerimientos y suposiciones a menudo no están garantizados en situaciones de decisiones reales. Por ejemplo, al establecer el rango de hábitat para una especie de aves particular, se debe usar evidencia en forma de observaciones registradas. No obstante, la ausencia de una observación en una ubicación no implica necesariamente que la especie no esté presente. Puede indicar simplemente que no había un observador presente, o que el observador no vio un ave que estaba presente. En casos como éste, la teoría Dempster-Shafer es apropiada (Gordon y Shortliffe, 1985; Srinivasan y Richards, 1990).

### Operadores de Agregado Dempster-Shafer

La jerarquía completa de hipótesis y las BPA asociadas con cada una de las anteriores, representan un estado de conocimiento que puede ser agregado en cualquier momento. Al agregar declaraciones de probabilidad de fuentes diferentes de evidencia, Dempster-Shafer emplea la siguiente regla de combinación:

$$m(Z) = \frac{\sum m_1(X) \cdot m_2(Y)}{1 - \sum m_1(X) \cdot m_2(Y)} \quad \begin{matrix} \text{when}(X \cap Y) = Z \\ \text{when}(X \cap Y) = \phi \end{matrix}$$

Si  $\sum m_1(X) \cdot m_2(Y) = 0$  para  $X \cap Y = \phi$  entonces la ecuación es

$$m(Z) = \sum m_1(X) \cdot m_2(Y) \quad \text{para} \quad X \cap Y = Z.$$

La creencia final, la posibilidad y el intervalo de creencia para cada una de las hipótesis luego se pueden deducir basándose en la asignación de probabilidad básica calculada con las ecuaciones anteriores. También se puede derivar la ignorancia para todo el grupo. En la mayoría de los casos, después de agregar evidencia nueva, la ignorancia se reduce.

### Trabajando con la Teoría Dempster-Shafer: Creencia

En IDRISI, el módulo Belief (creencia) puede usarse para implementar la lógica Dempster-Shafer. La convicción construye y almacena el estado de conocimiento actual para toda la jerarquía de hipótesis formada a partir de un marco de discernimiento. Además, tiene la habilidad de agregar evidencia nueva con ese conocimiento para crear un nuevo estado de conocimiento que puede consultarse en la forma de un mapa para la convicción, posibilidad o intervalo de creencia asociado con cualquier hipótesis.


La creencia primero necesita que los elementos básicos en el marco de discernimiento sean definidos. Tan pronto como los elementos son ingresados, todas las hipótesis en la estructura jerárquica son creadas en la lista de hipótesis. Para cada línea de evidencia ingresada, se necesitan imágenes (en forma de imágenes de números reales con un rango de 0-1) de asignación de probabilidad básica con una indicación de su hipótesis apoyada. El ítem BUILD KNOWLEDGE BASE (base para la construcción de conocimiento) en el menú ANALYSIS luego incorpora esta nueva evidencia al calcular de nuevo el estado de conocimiento usando la regla de combinación Dempster-Shafer. De esta evidencia se pueden seleccionar imágenes de resumen en la forma de creencia, posibilidad o intervalo de creencia para cada hipótesis. Toda la información ingresada se puede almacenar en un archivo de base de conocimiento para usar más tarde cuando se obtengan más evidencias.

La regla de combinación de Dempster-Shafer brinda un enfoque importante al agregado de evidencia indirecta y de información incompleta. Considere, por ejemplo, el problema de estimar dónde puede encontrarse un sitio

arqueológico de una cultura particular. El marco de decisión incluye dos elementos básicos, [sitio] y [no sitio].<sup>62</sup> Se usan cuatro evidencias:

las ubicaciones de los sitios conocidos, la frecuencia de los artefactos de la superficie (como trozos de cerámica), la proximidad a una fuente de agua permanente y las pendientes. Las primera puede verse como evidencia directa (en las posiciones exactas de los sitios mismos) para las áreas que poseen sitios arqueológicos conocidos. Sin embargo, lo que nos interesa son las áreas que no poseen un sitio para el cual los sitios conocidos no proveen información directa. Por ello, la evidencia es en gran medida indirecta. Para las áreas que se encuentran cerca de los sitios existentes, uno puede pensar que la probabilidad para la presencia de otro sitio es mayor. El módulo FUZZY se usa para transformar un mapa de distancia desde sitios conocidos en una imagen de probabilidad (una imagen de asignación de probabilidad básica en apoyo de la hipótesis del [sitio]).

La frecuencia de los artefactos de la superficie también se usa como evidencia en apoyo de la hipótesis del [sitio]. Las imágenes de las distancias a las fuentes de agua permanentes y de las pendientes, en cambio, han sido usadas como imágenes de descreimiento (ver la nota 1 en “Usando la Convicción” más adelante). A ambas se les ha trazado una escala en un rango de 0-1 usando FUZZY para brindar apoyo a la hipótesis del [no sitio]. La Figura 14-12 muestra estas imágenes de asignación de probabilidad básica.



**Figura 13-12 Imágenes de asignación de probabilidad usada en el agregado de evidencia para sitios arqueológicos.** De iz. a der., el BPA apoya la hypothesis [Site] basado en la distancia a sitios conocidos, [Site] basado en frecuencia de artefactos en superficie, [Non-Site] basado en distancia al agua permanente, y [Non-Site] basado en pendiente. Las áreas oscuras representan BPA más altos.

El módulo Belief combina información de las cuatro fuentes y ha sido usado para producir imágenes de creencia, posibilidad e intervalo de creencia para la hipótesis de [Sitio] como se ilustra en la Figura 14-13. La imagen de intervalo de creencia es particularmente interesante porque muestra dónde hay incertidumbre sustancial. Más muestras de evidencia en estas áreas pueden ser provechosas debido a que las condiciones apoyan la posibilidad de un sitio, aún cuando la evidencia concreta sea pobre.

### Usando la Convicción


1. Le puede resultar difícil decidir si una pieza de evidencia en particular debe usarse para apoyar la convicción de una hipótesis o, alternativamente, si el complemento de esa imagen debe usarse para apoyar su descreimiento. La segunda opción es en realidad una declaración en apoyo de la posibilidad de una hipótesis, pero no su descreimiento, y es muy común en SIG. Por ejemplo, en el caso anterior, la proximidad a una fuente de agua permanente fue tratada como una imagen de distancia en apoyo al descreimiento en la posibilidad de un sitio. El argumento de esto es que si uno estuviese cerca del agua no hay razón para creer que un sitio puede o no estar presente, pero si uno estuviese lejos del agua, hay una excelente razón para suponer que un sitio pudo no haber existido. Al decidir cómo tratar las líneas de evidencia, considere con cuidado si los datos proveen evidencia verdadera en apoyo a una hipótesis, o simplemente en apoyo a su posibilidad (es decir, la inhabilidad para negar su posibilidad).

<sup>62</sup> El número total de hipótesis que Dempster-Shafer genera en toda la jerarquía es  $2n-1$ . Implícitamente, hay una hipótesis extra que es el grupo nulo, que Dempster-Shafer supone que es automáticamente falsa. Entonces, en este ejemplo, la hipótesis [no sitio] no es el grupo nulo y tampoco Dempster-Shafer supone que es automáticamente falsa. En este ejemplo se ingresó como una hipótesis positiva y miembro del marco de discernimiento.

2. Para ingresar un descreimiento, indique que la evidencia apoya la colección de todas las hipótesis que no incluye la de interés. En el ejemplo de arqueología, la distancia al agua fue ingresada como evidencia para el [no sitio]. En un caso con tres hipótesis [A, B, C], para poder indicar que una línea particular de evidencia apoya el descreimiento en A, deberá indicar que ésta brinda apoyo a [B, C].

3. Por cada línea de evidencia que se incorpora usando Belief, asegúrese de ingresar todas las hipótesis apoyadas por una pieza particular de evidencia en una vuelta. La razón para esto es que Belief necesita llevar a cabo algunos cálculos internos relacionados con la ignorancia, y por ello, también necesita saber acerca de las hipótesis para las cuales esa evidencia no brinda apoyo. Solamente se precisa ingresar una imagen de asignación de probabilidad básica si la evidencia apoya la hipótesis en un grado mayor a cero. Para las hipótesis no apoyadas por la evidencia, el módulo supone una probabilidad de 0.

4. Para cada línea de evidencia, las imágenes de asignación de probabilidad básica deben ser imágenes de números reales con un rango que no exceda 0-1.



**Figura 14-13.** Imágenes: Creencia (izquierda), Plausibilidad (medio) e Intervalo de Creencia (derecha) para la presencia de sitios arqueológicos por combinación de evidencias antes de Dempster-Shafer.

## Incertidumbre de la Regla de Decisión y Riesgo de Decisión

En el contexto del error de medición, es muy común relacionar la incertidumbre con el riesgo de decisión. En IDRISI, el módulo PCLASS logra esto basándose en la lógica de grupos clásicos (como se discutió antes). Sin embargo, mientras nos movemos desde la interpretación bastante frecuente de la probabilidad asociada con el error de medición, a la relación más indirecta de creencias Bayesianas y Dempster-Shafer, al concepto bastante independiente de Grupos Difusos, nos movemos cada vez más lejos de la habilidad para establecer riesgo en algún sentido absoluto (Eastman, 1996). Es más, con una decisión basada en Grupos Difusos, podemos establecer que la inclusión de una alternativa es menos riesgosa que otra, pero no cuál es el riesgo en realidad. Entonces, en lugar de calcular el *riesgo absoluto*, debemos ser capaces de establecer un *riesgo relativo*.

El concepto de riesgo relativo es bastante familiar. Por ejemplo, al evaluar un grupo de candidatos para ser empleados, examinamos un número de criterios cuantificables – grados, gráficos de puntaje, años de experiencia, etc. – que permiten evaluar a los candidatos. Luego intentamos contratar los individuos mejores calificados sobre la suposición de que desempeñarán un buen trabajo. Sin embargo, no hay una escala absoluta por la cual entender la probabilidad de que éstos logren los objetivos que les propusimos. De manera similar, el módulo RANK de IDRISI puede usarse para calificar las adecuaciones logradas a través de un procedimiento de agrupamiento multicriterio. Este resultado luego puede ser dividido por la calificación máxima para producir una imagen de riesgo relativo. Posteriormente, este resultado es convertido en umbral para extraer un porcentaje específico de la mejor (es decir, menos riesgosa) solución disponible. La importancia de esta solución es que puede aplicarse en cualquier superficie de decisión sin importar la naturaleza de las incertidumbres involucradas.

## Comentario Final

Las herramientas de IDRISI para el apoyo en la toma de decisiones aún se encuentran en pleno desarrollo. Por lo tanto, le damos la bienvenida a comentarios y observaciones escritas para mejorar y perfeccionar su aplicación en situaciones reales.

## Referencias / Lectura Complementaria

- Alonso, W., 1968. Predicting Best with Imperfect Data, *Journal of the American Institute of Planners*, 34: 248-255.
- Bonham-Carter, G.F., Agterberg, F.P. y Wright, D.F., 1988. Integration of Geological Datasets for Gold Exploration in Nova Scotia, *Photogrammetric Engineering and Remote Sensing*, 54(11): 1585-1592.
- Bonissone, P.P. y Decker, K., 1986. Selecting Uncertainty Calculi and Granularity: An Experiment in Trading-Off Precision and Complexity. In L.N. Kanal y J.F. Lemmer eds., *Uncertainty in Artificial Intelligence*, Elsevier Science, Holland.
- Burrough, P.A., 1986. *Principles of Geographical Information Systems for Land Resources Assessment*, Clarendon Press, Oxford.
- Congalton, R.G., 1991. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data, *Remote Sensing and the Environment*, 37: 35-46.
- Eastman, J.R., 1996. Uncertainty and Decision Risk in Multi-Criteria Evaluation: Implications for GIS Software Design, *Proceedings, UN University International Institute for Software Technology Expert Group Workshop on Software Technology for Agenda'21: Decision Support Systems*, del 26 de febrero al 8 de marzo.
- Eastman, J.R., Kyem, P.A.K., Toledano, J. y Jin, W., 1993. *GIS and Decision Making*, Explorations in Geographic Information System Technology, 4, UNITAR, Génova.
- Fisher, P.F., 1991. First Experiments in Viewshed Uncertainty: The Accuracy of the Viewshed Area, *Photogrammetric Engineering & Remote Sensing* 57(10): 1321-1327.
- Goodchild, M.F., y Gopal, S., eds., 1989. *Accuracy of Spatial Databases*. Taylor y Francis, Londres.
- Gordon, J., y Shortliffe, E.H., 1985. A Method for Managing Evidential Reasoning in a Hierarchical Hypothesis Space, *Artificial Intelligence*, 26: 323-357.
- Honea, R.B., Hake, K.A., y Durfee, R.C., 1991. Incorporating GISs into Decision Support Systems: Where Have We Come From and Where Do We Need to Go? In: M. Heit y A. Shortreid (eds.), *GIS Applications in Natural Resources*. GIS World, Inc., Fort Collins, Colorado.
- Klir, George J., 1989. Is There More to Uncertainty Than Some Probability Theorists Might Have Us Believe? *International Journal of General Systems*, 15: 347-378.
- Lee, N.S., Grize, Y.L. y Dehnad, K., 1987. Quantitative Models for Reasoning Under Uncertainty in Knowledge-Based Expert Systems, *International Journal of Intelligent Systems*, 2: 15-38.
- Maling, D.H., 1989. *Measurement from Maps: Principles and Methods of Cartography*, Pergamon Press, Oxford.
- Moellering, H., 1988. Digital Cartographic Data Quality. *The American Cartographer* 15(1).
- Schmucker, K.J., 1982. *Fuzzy Sets, Natural Language Computations and Risk Analysis*. Computer Science Press.
- Slonecker, E.T. y Tosta, N., 1992. National Map Accuracy: Out of Sync, Out of Time. *Geoinfo Systems*, 2(1): 23-26.
- Stoms, D., 1987. Reasoning with Uncertainty in Intelligent Geographic Information Systems. *Proceedings, GIS '87*, 692- 700.

Srinivasan, A. y Richards, J.A., 1990. Knowledge-Based Techniques for Multi-Source Classification. *International Journal of Remote Sensing*, 11(3): 505-525.

Yager, R. 1988. On Ordered Weighted Averaging Aggregation Operators in Multicriteria Decision Making, *IEEE Transactions on Systems, Man, and Cybernetics*. 8(1): 183-190.

Zadeh, L.A., 1965. Fuzzy Sets. *Information and Control*, 8: 338-353.

# CAPÍTULO 15 - Restauración de Imágenes

En el capítulo **Introducción a los Sensores Remotos y al Procesamiento de Imágenes**, la restauración de imágenes se divide en dos grandes subáreas: restauración radiométrica y restauración geométrica. La restauración radiométrica se ocupa de la fidelidad de las lecturas de energía electromagnética por parte del sensor, mientras que la restauración geométrica se ocupa de la fidelidad espacial de las imágenes. No obstante, mientras que la palabra restauración sugiere un regreso a las condiciones que existieron una vez, la realidad es que la restauración de imágenes se ocupa de establecer las condiciones de medición que probablemente nunca existieron – la medición de características radiométricas bajo condiciones perfectas e invariables en un elipsoide abstracto de referencia. La medición de las características radiométricas se hace cargo entonces de temas tales como la neblina atmosférica, la calibración del sensor, las influencias topográficas sobre la iluminación, el ruido del sistema, etc. Las restauraciones geométricas son menos carga para el usuario común de datos debido a que la mayoría de éstas ya están completadas por el distribuidor de imágenes. La tarea más significativa que debe cumplir el usuario de datos es el georeferenciamiento. Todas estas rectificaciones se pueden lograr usando los módulos existentes de IDRISI.

## Restauración Radiométrica

### Calibración del Sensor

Los detectores de los sensores pueden variar entre instrumentos (como en satélites sucesivos en una serie, como los satélites meteorológicos NOAA TIROS-N) y dentro de un mismo instrumento a lo largo del tiempo o por encima de la cara de la imagen si se usan múltiples detectores (como normalmente se hace). La calibración de los sensores se ocupa entonces de asegurar la uniformidad de la producción por toda la cara de la imagen, y a través del tiempo.

### Calibración de la Radiancia

Los valores de los píxeles en las imágenes satelitales expresan la cantidad de energía radiante recibida por el sensor en la forma de valores relativos no calibrados simplemente llamados Números Digitales (DN). A veces, estos DN se los conoce como los valores del brillo. Para muchas (quizás la mayor parte) aplicaciones en la teledetección (como la clasificación de una imagen de fecha única usando clasificación no supervisada), no es necesario convertir estos valores. Sin embargo, la conversión de DN en valores de radiancia absolutos es un procedimiento necesario para el análisis comparativo de varias imágenes tomadas por distintos sensores (por ejemplo, LANSAT-2 versus LANDSAT-5). Debido a que cada sensor tiene sus propios parámetros de clasificación usados en el almacenamiento de los valores DN, los mismos valores DN en dos imágenes tomadas por dos sensores diferentes pueden representar en realidad dos valores de radiancia diferentes.

Usualmente, los detectores están calibrados de manera tal que hay una relación lineal entre los DN y la radiancia espectral. Esta función lineal es típicamente descrita por tres parámetros: el rango de valores DN en la imagen, la radiación más baja ( $L_{min}$ ) y la radiación más alta ( $L_{max}$ ) medidas por un detector sobre el ancho de banda espectral del canal. La mayoría de las veces, los datos son distribuidos en formato de 8 bits correspondiente a los niveles 256 DN.  $L_{min}$  es la radiación espectral correspondiente al valor DN mínimo (usualmente 0).  $L_{max}$  es la radiación correspondiente al valor DN (usualmente 255). No solo cada sensor, sino que también cada banda dentro del mismo sensor tiene su propio  $L_{min}$  y  $L_{max}$ . La información acerca de los parámetros de calibración de los sensores ( $L_{min}$  y  $L_{max}$ ) generalmente es ofrecida con los datos o se encuentra disponible en algún otro lugar.<sup>63</sup> La ecuación<sup>64</sup> que relaciona los DN en los datos de sensores remotos con la radiancia es:

$$L = \left( \frac{L_{max} - L_{min}}{255} \right) DN + L_{min}$$

donde  $L$  es la radiancia expresada en  $Wm^{-2} sr^{-1}$ .

<sup>63</sup> Los parámetros de calibración de los satélites LANDSAT pueden encontrarse en: EOSAT LANDSAT Technical Notes No. 1, Agosto 1986, o en LANDSAT Data User's Handbook.

<sup>64</sup> Para una explicación de la computación de la radiancia de los DN, puede consultar: Lillesand, T.M. and R.W. Kiefer, 1994. *Remote Sensing and Image Interpretation*. Third Edition. John Wiley and Sons.

Alternativamente, la calibración del sensor puede ser expresada en la forma de compensación y ganancia. En este caso, la radiancia puede calcularse como:

$$L = \text{Compensación} + (\text{Ganancia} \times \text{DN})$$

Tenga en cuenta que también es posible convertir entre una especificación Compensación/Ganancia y  $L_{\min}/L_{\max}$  de la siguiente manera:

$$\text{Compensación} = L_{\min}$$

$$\text{Ganancia} = \frac{L_{\max} - L_{\min}}{255}$$

o alternativamente:

$$L_{\min} = \text{Compensación}$$

$$L_{\max} = (\text{Ganancia} \times 255) + L_{\min}$$

Se puede usar tanto el módulo CALIBRATE como el RADIANCE de IDRISI para convertir valores DN puros en radiancias calibradas. El módulo RADIANCE tiene más opciones. Contiene una tabla de búsqueda de  $L_{\min}$  y  $L_{\max}$  para los sensores MSS y TM de LANDSAT 1-5. Para otros sistemas satelitales, le permite al usuario ingresar valores  $L_{\min}/L_{\max}$  o Compensación/Ganancia específicos de determinados sistemas. CALIBRATE está particularmente dirigido a la combinación del nivel del brillo, pero también permite un ajuste en una compensación y ganancia específicas.

En cualquiera de los casos, se debe tener especial cuidado para que los coeficientes de la calibración coincidan correctamente con las unidades de salida deseadas. La expresión más común de radiancia es en  $\text{Wcm}^{-2}\text{sr}^{-1}$  (es decir, milliWatts por centímetro cuadrado por estereadian por micrón). Sin embargo, también es común encontrar  $\text{Wmc}^{-2}\text{sr}^{-1} \text{ mm}^{-1}$  (es decir, Watts por metro cuadrado por estereadian por micrón).

## Bandeado

El Rayado o Bandeado es ruido sistemático en una imagen que resulta de la variación en la respuesta de los sensores individuales usados para una banda particular. Esto usualmente ocurre cuando un detector se desajusta y produce lecturas que son de manera consistente mucho más altas o mucho más bajas que las de los demás detectores para la misma banda.

En el caso de datos MSS, hay 6 detectores por banda que escanean en una dirección horizontal. Si uno de los detectores está descalibrado, el bandeo horizontal ocurre respectivamente en cada línea número 6. De manera similar, en el caso de datos TM con 16 detectores por banda, afectará cada línea número 16 en la imagen. Los datos multiespectrales SPOT tienen un escáner de barrido con 3000 detectores por cada banda, un detector por cada pixel en una fila. Debido a que los detectores en un escáner de barrido están distribuidos en una línea perpendicular a la órbita del satélite, la descalibración en los detectores del SPOT produce un bandeo vertical. Como el satélite SPOT posee un detector individual para cada columna de datos, no existe un patrón de bandeo repetitivo en la imagen.

El procedimiento que corrige los valores en las líneas de escaneo erróneo se llama *desbandeado*. Requiere el cálculo de la desviación promedio (o media) y estándar de toda la imagen y luego de cada detector por separado. Algunos paquetes software ofrecen una opción para aplicar una máscara a la imagen para poder excluir ciertas áreas de estos cálculos (por ejemplo, si las nubes y las sombras de éstas deben excluirse). Además, a veces solo una porción de la imagen, usualmente un área homogénea como un cuerpo de agua, se usa para estos cálculos. Luego, dependiendo del algoritmo empleado por un sistema software, se realiza uno de los siguientes ajustes:

1. La producción de cada detector es escalada para coincidir con la desviación promedio y estándar de toda la imagen. En este caso, el valor de cada pixel en la imagen es alterado.

2. La producción del detector con el problema es escalada para parecerse a la desviación promedio y estándar de los otros detectores. En este caso, los valores de los pixeles en las líneas normales de los datos no son alterados. El módulo DESTRIPE de IDRISI emplea el primer método. Los resultados de esta transformación se muestran en las Figuras 14-1 y 14-2.



Si los datos satelitales son adquiridos de un distribuidor completamente georeferenciado, entonces la corrección radiométrica por medio de DESTRIPE no es posible. En este caso sugerimos una metodología deferente. Uno puede ejecutar un Análisis de Componentes Principales No Estandarizados en la colección de bandas de entrada. Los últimos componentes por lo general representan menos del 1 por ciento de la información total disponible y tienden a retener información relevante al bandeo. Si estos componentes son eliminados completamente y el resto de los componentes son reensamblados, la mejora es bastante grande ya que el efecto de bandeo hasta puede desaparecer. Para reensamblar imágenes compuestas, es necesario guardar la información de tabla que reporta los *vectores propios* para cada componente. En esta tabla, las filas están ordenadas de acuerdo al número de bandas. Los *vectores propios* de columnas que leen de izquierda a derecha representan el grupo de coeficientes de transformación necesarios para transformar linealmente las bandas para luego producir los componentes. De manera similar, cada fila representa los coeficientes de la transformación inversa de los componentes en las bandas originales. Al multiplicar cada imagen de componentes por su elemento *vector propio* correspondiente por una banda particular y al sumar todos los componentes ponderados, se reproduce la banda original de información. Si los componentes de ruido son simplemente excluidos de la ecuación, es posible computar las nuevas bandas, libres de estos efectos. Esto puede lograrse con rapidez usando el Image Calculador de IDRISI.

El capítulo sobre **Análisis Fourier** detalla cómo también puede usarse esa técnica para eliminar el bandeo o ruido de imágenes satelitales.



**Figura 15-1**



**Figura 15-2**

## Efecto Mosaico

El efecto mosaico se refiere al proceso de combinación de las características radiométricas de un grupo de imágenes que ensamblan para producir un compuesto más grande. En IDRISI, el módulo MOSAIC facilita este proceso. La lógica básica es ecualizar los promedios y las varianzas de los valores almacenados en todo el grupo de imágenes, basándose en un análisis de valores comparativos en áreas superpuestas. La primera imagen especificada actúa como la principal, a la cual se ajustan todas las otras imágenes.

## Corrección Atmosférica

La atmósfera puede afectar la naturaleza de las imágenes de sensores remotos en un número de formas diferentes. A nivel molecular, los gases atmosféricos causan dispersión Rayleigh que afecta progresivamente las longitudes de banda más cortas (provocando, por ejemplo, que el cielo se vea azul). Además, los componentes atmosféricos principales como el oxígeno, el dióxido de carbono, el ozono y el vapor de agua (particularmente los dos últimos) causan la absorción de energía en longitudes de banda seleccionadas. Las partículas de aerosol (un aerosol es una suspensión gaseosa de partículas líquidas o de sólidos finos) son el principal determinante de la neblina, e introducen una dispersión Mie en gran medida no selectiva (es decir, que afecta a todas las longitudes de banda por igual). Los efectos atmosféricos pueden ser sustanciales (ver Figura 15-3). Por lo tanto, los especialistas en sensores remotos han trabajado en la modelación y la corrección de estos efectos. IDRISI ofrece varios enfoques hacia la corrección atmosférica, cuyo módulo más sofisticado es el ATMOSC.

## Modelo de Sustracción de Objetos Oscuros

El efecto de la neblina es normalmente una elevación relativamente uniforme en los valores espectrales en las bandas visibles de energía. Una forma para reducir la neblina en las imágenes es buscar los valores en las áreas de reflectancia cero conocida, como las aguas profundas. Cualquier valor mayor que cero en estas áreas es probable que represente un aumento general en los valores de la imagen y puede ser sustraído fácilmente de todos los valores en la banda individual usando SCALAR. No obstante, ATMOSC también ofrece un modelo de Sustracción de Objetos

Oscuros con el beneficio agregado de que compensa las variaciones en las producciones solares según el momento del año y el ángulo de elevación solar. Para realizar esto, se requiere la misma estimación del Dn de neblina (Ej.: el Dn de lagos profundos y claros), fecha y hora de la imagen, longitud de onda central de la banda de imagen, elevación solar y parámetros de conversión de la radiancia. Estos parámetros adicionales están normalmente incluidos con la documentación para las imágenes de sensores remotos.

### Modelo de Costo

Una de las dificultades de la corrección atmosférica es que los datos necesarios para un ajuste completo a menudo no se encuentran disponibles. El modelo de Costo fue diseñado por Chavez (1996) como una técnica para la aproximación que funciona bien en estos casos. También está disponible en el módulo ATMOSC e incorpora todos los elementos del modelo de Sustracción de Objetos Oscuros (para la remoción de neblina) más un procedimiento para calcular los efectos de la absorción por parte de los gases atmosféricos y de la dispersión Rayleigh. No requiere parámetros adicionales sobre el modelo de Sustracción de Objetos Oscuros, y por otra parte, estima estos elementos adicionales basándose en el coseno del ángulo cenit del sol ( $90 - \text{elevación solar}$ ).

### Modelo de Corrección Completa

El modelo completo es el más exigente en términos de los requerimientos de datos. Además de los parámetros necesarios para los modelos de Sustracción de Objetos Oscuros y de Costo, requiere una estimación del grosor óptico de la atmósfera (el Sistema de Ayuda para ARMOSC brinda una guía para esto) y de la irradiación espectral difusa del cielo (la irradiación difusa hacia abajo del cielo en la longitud de onda en cuestión generada a partir de la dispersión – ver Forster (1984) and Turner and Spencer (1972). En los casos en que esto se desconoce, se puede usar el valor por defecto de 0.

### Modelo de Reflectancia Aparente

ATMOSC ofrece un cuarto modelo conocido como el Modelo de Reflectancia Aparente. Éste es raramente usado ya que realiza un ajuste muy pequeño del efecto atmosférico (sólo ajusta la elevación solar, y por consiguiente, el grosor efectivo de la atmósfera). Está incluido, sin embargo, como un medio para convertir DN en valores de reflectancia aproximados.

### Estrategia Alternativa para la Eliminación de Neblina

Otro método efectivo para reducir la neblina requiere la aplicación del Análisis de los Componentes Principales. El módulo PCA en IDRISI separa una colección de bandas en componentes distribuidos estadísticamente. El método para eliminar un componente se describe en la sección *Efectos del Ruido* (este capítulo) para la eliminación del bandeo de imágenes. Aconsejamos usar este método para reducir también cualquier otro efecto atmosférico. Las Figuras 15-3 y 15-4 son imágenes TM LANDSAT de Banda 1 antes y después de la restauración. El área se encuentra en Vietnam norte-central en un momento con cantidades tan enormes de neblina relativas a la reflectancia del suelo que también hacen el bandeo del sensor bastante aparente. El Análisis de los Componentes Principales fue aplicado sobre las siete bandas



Figura 15-3



Figura 15-4

### Efectos Topográficos

El *Efecto Topográfico*<sup>65</sup> se define simplemente como la diferencia en valores de radiancia de superficies inclinadas comparadas con superficies horizontales. La interacción del ángulo y del acimut de los rayos solares con pendientes

<sup>65</sup> La sección Efectos Topográficos está tomada del ejercicio "Mitigating Topographic Effects in Satellite Imagery" en Schneider and Robbins, 1995. *UNITAR Explorations in GIS Technology*, Volume 5, *GIS and Mountain Environments*, UNITAR, Geneva, también disponible a través de Clark Labs.

y diferentes aspectos produce efectos topográficos que resultan en una iluminación variable. Las imágenes son a menudo tomadas en las primeras horas de la mañana o en las últimas horas de la tarde, cuando el efecto del ángulo solar sobre la iluminación de las pendientes puede ser extremo. En ambientes montañosos, las reflectancias de las pendientes que miran en sentido contrario al sol son considerablemente más bajas que la reflectancia general o el promedio del área de una imagen. En condiciones extremas de terreno, algunas áreas pueden ser ensombrecidas a tal punto que se pierde toda información significativa.

Los efectos de sombreado y dispersión exageran la diferencia en la información de reflectancia proveniente de materiales terrestres similares. La firma del mismo tipo de cobertura terrestre de pendientes enfrentadas opuestas no sólo tiene promedio y varianza diferentes, sino que hasta puede tener rangos de reflectancia no superpuesta. En el proceso de clasificación, la relación altamente variable entre pendiente, cobertura terrestre y ángulo solar puede llevar a un número bastante exagerado de grupos de reflectancia que hacen que la interpretación final de las capas de datos sea más costosa, difícil y larga. Aún cuando las coberturas terrestres no son las mismas en lados opuestos de la montaña (a menudo éste es el caso ya que la pendiente y el aspecto ayudan a determinar el tipo de cobertura terrestre presente), la iluminación variable dificulta la derivación de los índices de biomasa o la realización de otras comparaciones entre clases de cobertura terrestre.

Muchas técnicas para disminuir el efecto topográfico han evolucionado en los últimos años. Sin embargo, muchas tienden a ser apropiadas solamente para el ambiente específico en el cual fueron desarrolladas, o requieren datos auxiliares bastante detallados que a menudo no están disponibles. Las tres técnicas más accesibles usadas son la tasación de bandas, la división de una imagen en áreas separadas para clasificación y la modelación de la iluminación basado en un DEM. Las técnicas más sofisticadas (que no son discutidas aquí) incluyen la modelación de los efectos de iluminación tales como los efectos de dispersión inversa y difusión indirecta.

## **Tasación de Bandas**

En la tasación de bandas, una imagen de banda se divide por otra.

BandA

BandB

La imagen de salida resultante es luego ampliada linealmente a la inversa al rango de valores 0 a 255, y utilizada para la clasificación de imágenes. La tasación de bandas está basada en el principio de que las variaciones de terreno (en pendiente y aspecto) causan variaciones en la iluminación consistentes en diferentes longitudes de banda. Entonces, en un área con una cobertura terrestre uniforme, la reflectancia relativa de una banda hacia otra será la misma sin importar las variaciones de pendiente y aspecto. La tasación de bandas es la técnica más simple para realizar en los casos de disminución del efecto topográfico. No es muy efectiva, sin embargo, cuando la varianza en los rangos de firmas está altamente comprimida. Esto ocurre comúnmente en condiciones de ensombrecimiento extremo.

## **División de Imágenes**

La división de imágenes funciona a partir del simple criterio de que debido a que los efectos de iluminación provocados por pendientes y aspectos afectan las diferentes áreas dentro de una imagen de manera diferente, estas áreas distintas deben ser clasificadas por separado. Al usar un modelo de elevación digital para producir imágenes de máscara, las bandas se subdividen según las diferentes categorías de elevación, pendiente y aspecto. Estas subescenas luego son clasificadas por separado y los resultados son recombinados después de la clasificación. De manera similar a la tasación de bandas, esta técnica es simple e intuitiva, pero sólo es efectiva bajo las condiciones apropiadas. La división funciona mejor donde las condiciones de cobertura terrestre están estratificadas ambientalmente. En caso contrario, existe la posibilidad de que se creen cientos de grupos sin significado cuando se usa una clasificación no supervisada, o de que se clasifiquen los píxeles erróneamente cuando se aplican técnicas supervisadas.

El grupo de umbrales para pendiente, aspecto y elevación dependen del ángulo solar y el acimut conocidos. Sin la información solar, los umbrales significativos del efecto topográfico pueden determinarse equivocadamente al analizar visualmente el efecto de la sombra. La inscripción del DEM en los datos satelitales debe ser tan precisa como sea posible.

De lo contrario, la naturaleza inexacta de los umbrales aumenta la probabilidad de obtener clasificaciones menos significativas.

## **Modelo de Iluminación**

Las herramientas analíticas asociadas con la mayoría de los sistemas software de SIG raster ofrecen una técnica muy efectiva para la modelación de los efectos de la iluminación. Los pasos de IDRISI son los siguientes:

1. Use HISTO para calcular el promedio de banda de la imagen para corregir.
2. Use un Modelo de Elevación Digital (DEM) para el área de la imagen y aplique el módulo HILLSHADE (SURFACE) para crear un mapa de sombreado analítico. Este va a ser el modelo de los efectos de iluminación de todas las bandas y simplemente necesita ser calibrado para usarse.
3. Use REGRESS para calcular la relación lineal entre el mapa de sombreado y la imagen a corregir. Use la imagen como la variable dependiente y el sombreado como la variable independiente.
4. Use CALIBRATE para aplicar la compensación (la ordenada al origen de la ecuación de regresión) y la ganancia (la pendiente de la ecuación de regresión) en el mapa de sombreado. El resultado es un modelo de componente de iluminación inducida por el terreno.
5. Use Image Calculador para restar el resultado del paso anterior de la imagen original y luego agregar el promedio calculado en el primer paso. El resultado es una estimación razonable de cómo se hubiera visto la imagen si el suelo hubiera sido plano.

## Ruido

El ruido ocurre en las imágenes debido a cualquier número de interferencias mecánicas o electrónicas en el sistema del sensor que llevan a errores de transmisión. El ruido degrada la señal grabada o prácticamente elimina toda la información radiométrica. El ruido puede ser sistemático, como el mal funcionamiento periódico de un detector, resultando en el rayado o bandeado de la imagen. O bien puede ser de carácter más aleatorio, y causar variaciones radiométricas descritas una apariencia de “sal y pimienta”. En las imágenes RADAR, las “manchas” ocurren porque la interacción de la señal con ciertos bordes de objetos o edificios produce un registro muy elevado, que cuando es frecuente, tiene un efecto similar al ruido “sal y pimienta”.

## Pérdida de Líneas de Escaneo

La pérdida de líneas de escaneo ocurre cuando la pérdida de señal temporal de detectores específicos provoca una pérdida completa para las líneas afectadas. En IDRISI, este problema puede solucionarse gracias a una secuencia de pasos. Primero reclasifique la banda afectada con RECLASS para crear una imagen de máscara booleana en la cual los píxeles con líneas perdidas presentes tienen un valor de 1 y el resto, un valor de cero. Luego, para las líneas perdidas horizontales, ejecute un FILTER 3 x 3 definido por el usuario en la banda original con los siguientes valores kernel:

0	0,5	0
0	0	0
0	0,5	0

Esto tendrá el efecto de asignar a cada pixel el promedio de los valores en las líneas de escaneo superiores e inferiores. Si la línea perdida es vertical, simplemente rote los valores kernel del filtro en 90 grados. Luego, use OVERLAY para multiplicar la máscara y la imagen filtrada juntas. Esto crea un resultado en el cual los valores filtrados sólo aparecen en aquellas posiciones donde las líneas de escaneo se han perdido. Superponga este resultado sobre la banda original usando la operación COVER, que hará que estos valores sólo se coloquen donde se han perdido datos.

## Ruido “Sal y Pimienta”

El ruido aleatorio a menudo produce valores que son increíblemente altos o bajos en relación a los valores de los píxeles vecinos. Dada la suposición de que los valores de reflectancia ruidosos muestran cambios abruptos en la

reflectancia de pixel a pixel, es posible usar operaciones de filtrado para reemplazar estos valores con otro valor generado a partir de la interpretación de píxeles vecinos. El FILTER de IDRISI provee varias opciones para este propósito. Comúnmente se aplican filtros de media de 3 x 3 o de 5 x 5. Los píxeles ruidosos son reemplazados por el valor medio seleccionado entre los vecinos de la ventana especificada. Debido a que todos los píxeles son procesados por el filtrado medio, algunos detalles y bordes pueden perderse. Esto es especialmente problemático con las imágenes RADAR debido al nivel particularmente alto de manchas que se puede dar. Por lo tanto, hemos incluido un filtro de Cuadro Adaptable que es una extensión del filtro Lee común. El filtro de Cuadro Adaptable

determina localmente dentro de una ventana especificada (3 x 3, 5 x 5 o 7 x 7) el rango de valores promedio y mín./máx. basándose en una desviación estándar especificada por el usuario. Si el valor de ventana central se encuentra fuera del rango especificado por el usuario, entonces se asume que es ruido y el valor es reemplazado por un promedio de los vecinos próximos. Puede elegir la opción de reemplazar el valor con un cero. El filtro también le permite al usuario especificar una varianza de umbral mínima para proteger los píxeles en las áreas de variación muy baja. Vea el Sistema de Ayuda on-line del módulo FILTER para aprender más sobre este enfoque bastante flexible.

## Restauración Geométrica

Como se mencionó en el capítulo **Introducción a los Sensores Remotos y al Procesamiento de Imágenes**, la mayoría de los elementos de la restauración geométrica asociados con la captación de imágenes son corregidos por los distribuidores de las imágenes, en especial la *corrección de desviaciones* y la *corrección de la distorsión del escáner*. Los distribuidores también venden imágenes que ya se encuentran *georeferenciadas*. El georeferenciamiento no es sólo una técnica de restauración sino un método con el cual se reorientan los datos para satisfacer los deseos y los requerimientos de proyecto del usuario de datos. Es particularmente importante que las imágenes georeferenciadas cumplan con los estándares del usuario de datos y se inscriba bien con otros datos en la misma proyección y el mismo sistema de referencia.

Es nuestra experiencia que aún si los estándares propios no son muy estrictos para una tarea particular con imágenes, vale la pena invertir tiempo en georeferenciar uno mismo la imagen en lugar de que lo haga el distribuidor. Esto es verdadero por un número de razones. Primero, algunas correcciones radiométricas se vuelven más difíciles (si no imposibles) de realizar si los datos ya están georeferenciados. La habilidad para reducir los efectos de bandeo, eliminación de la línea de escaneo y efectos topográficos sobre la iluminación es de particular interés. Si la orientación geométrica de los efectos es alterada, entonces las técnicas de restauración estándar se vuelven inútiles. Debido a que la severidad de estos efectos usualmente no se conoce antes de recibir los datos, georeferenciar los datos uno mismo es importante para mantener el control sobre el proceso de restauración de la imagen.

Otra razón para georeferenciar las imágenes uno mismo es para ganar más control sobre las incertidumbres espaciales producidas por el proceso de georeferenciamiento. Sólo entonces es posible saber cuántos puntos de control son utilizados, dónde están ubicados, qué calidad posee cada uno individualmente y cuál es la combinación de puntos de control más satisfactoria para seleccionar. El módulo RESAMPLE de IDRISI le brinda al usuario un control significativo sobre este proceso. El usuario puede eliminar y agregar puntos libremente y evaluar los efectos sobre el error RMS en general y los residuos individuales de los puntos mientras son aplicados en una nueva ecuación. Esta evaluación interactiva es especialmente importante si se requiere un *rubbersheeting* significativo para distorsionar los datos para que éstos cumplan con las necesidades de proyección del área de uno.

Vea el capítulo **Georeferenciamiento** para un abordaje más amplio de este tema. Vea además el ejercicio sobre Georeferenciamiento en el **Tutorial** para obtener un ejemplo elaborado de cómo se usa el módulo RESAMPLE en IDRISI para georeferenciar una imagen satelital.

## Referencias

Chavez, P.S., (1996) "Image-Based Atmospheric Corrections - Revisited and Improved", Photogrammetric Engineering and Remote Sensing, 62, 9, 1025-1036.

Forster, B.C., (1984) "Derivation of atmospheric correction procedures for LANDSAT MSS with particular reference to urban data", International Journal of Remote Sensing, 5, 5, 799-817.

Lillesand, T.M. and R.W. Kiefer, (1994) *Remote Sensing and Image Interpretation*. Tercera Edición. John Wiley and Sons.

Turner, R.E., and Spencer, M.M., (1972) "Atmospheric Model for Correction of Spacecraft Data", Proceedings, Octavo Simposio Internacional sobre los Sensores Remotos del Medio Ambiente, Vol. II, 895-934.

# CAPÍTULO 16 - Análisis de Fourier

El Análisis de Fourier es una técnica de descomposición de señal/imagen que intenta describir la estructura subyacente de una imagen como una combinación de elementos más simples. Específicamente, intenta describir la señal/imagen como una composición de ondas sinusoidales simples. Por ello el objetivo del Análisis de Fourier es de alguna manera similar al del Análisis de Componentes Principales – para dividir la imagen en sus componentes estructurales con el propósito de analizar y modificar esos componentes antes de una reconstrucción eventual en una forma mejorada. Mientras que el Análisis de Fourier tiene aplicación en un número de campos desde la óptica a la electrónica, en el contexto del procesamiento de imágenes, es mayormente usado para la eliminación de ruidos.

## La Lógica del Análisis de Fourier

Desafortunadamente, el tratamiento matemático del Análisis de Fourier lo hace conceptualmente inaccesible para muchos. Debido a que hay suficientes tratamientos del Análisis de Fourier desde una perspectiva matemática, la descripción ofrecida aquí está preparada como un tratamiento más conceptual.

Una imagen puede ser conceptualmente entendida como una forma de ondas complejas. Por ejemplo, si uno dibujase los niveles grises a lo largo de cualquier fila o columna, éstos formarían el carácter de una onda compleja. Para una imagen bidimensional, la extensión lógica de esta sería una superficie, como la superficie de un océano o lago. Imagínese dejar caer una piedra en un estanque– se formaría un patrón simple de ondas sinusoidales con una longitud de onda que depende del tamaño de la piedra. Ahora imagínese dejar caer un conjunto de piedras de diferentes tamaños y en diferentes lugares. En algunos lugares, las ondas se anulan unas con otras, mientras que en otros lugares una onda refuerza a otra, produciendo ondas de mayor amplitud aún. La superficie del estanque exhibe entonces un patrón de ondas complejo creado finalmente por un grupo de formas de ondas muy simples. Las Figuras 16-1 y 15-6 ilustran este efecto. La Figura 16-1 muestra una serie de ondas sinusoidales de frecuencia, amplitud y fase variables (estos términos se explicarán más adelante). La Figura 16-2 muestra la forma de onda compleja que resulta de la combinación de estas ondas.




Figura 16-1




Figura 16-2

El Análisis de Fourier usa esta lógica a la inversa. Comienza con una forma de onda compleja y supone que este es el resultado del los efectos aditivos de ondas sinusoidales simples de *frecuencia*, *amplitud* y *fase* variables. La frecuencia se refiere al número de longitudes de onda completas que ocurren en una distancia especificada. La Figura 16-3 muestra una serie de ondas sinusoidales que sólo difieren en su frecuencia. La amplitud se refiere a la altura o fuerza de la onda. La Figura 16-4 muestra una serie de ondas sinusoidales que sólo varían en amplitud. Finalmente, la fase se refiere a la compensación de la cresta de la primera onda desde el origen. La Figura 16-5 muestra una serie de ondas que sólo varían en fase. En la descomposición de imágenes digitales, se toma un grupo finito de ondas que varía desde la onda de menor frecuencia que complete una sola longitud de onda en la extensión de la imagen en X e Y, a una onda que completa 2 longitudes de onda en esa extensión, a 3 longitudes de onda, y así sucesivamente, hasta la onda de mayor frecuencia con una longitud de onda igual al doble de la resolución del pixel (conocida como la *frecuencia Nyquist* ). Entonces, la tarea del proceso del Análisis de Fourier es simplemente la estimación de la fase y de las amplitudes de estas ondas.






Figura 16-3




Figura 16-4




Figura 16-5

## Cómo Funciona el Análisis de Fourier

La manera más fácil para entender cómo funciona el Análisis de Fourier es usar una analogía. En la presencia de un sonido (una forma de onda compleja), la cuerda de una guitarra (o de cualquier otro instrumento a cuerdas) vibra o resuena si el sonido contiene la misma nota (frecuencia). La fuerza de esa vibración armónica es una función de la amplitud de esa nota dentro del sonido original. En esencia, así es como funciona el Análisis de Fourier – “escucha” el grado de resonancia de un grupo de frecuencias específicas con el sonido (imagen) analizado. Es como colocar un arpa en la presencia de un sonido, y medir el grado en el cual resuena cada cuerda.

El proceso de comprobación de la presencia de frecuencias variables se logra al multiplicar la onda compleja por la amplitud correspondiente de la onda de seno que está siendo evaluada, y luego se suman los resultados. La suma resultante es la resonancia en esa frecuencia. El único problema es la fase. ¿Qué ocurre si la onda en cuestión está presente, pero la onda de prueba se encuentra fuera de fase? En el peor de los casos, están exactamente fuera de fase, de manera tal que los picos en la frecuencia de prueba están nivelados por los puntos mínimos en la onda compleja – el efecto neto es que éstas se eliminarán mutuamente, haciéndonos creer que la onda directamente no está presente.

La respuesta al problema de la fase es probar la onda compleja comparándola con dos versiones de la onda de igual frecuencia, exactamente fuera de fase una con otra. Esto se puede realizar fácilmente probando una onda de seno y una onda de coseno de igual frecuencia (debido a que los senos y cosenos son idénticos a excepción de que se encuentran exactamente fuera de fase). De esta manera, si hay poca resonancia con la onda de seno debido a un problema de fase, queda garantizada la resonancia con la onda coseno.<sup>66</sup>

## Interpretando la Expresión Matemática

Dada la discusión anterior, la fórmula para la Serie Fourier no es tan difícil de entender. Considerando el caso unidimensional, la función compleja de  $x$  puede describirse como la suma de los componentes seno y coseno de la siguiente manera:

$$f(x) = a_0 + \sum_{k=1} (a_k \cos(k\omega x) + b_k \sin(k\omega x))$$

<sup>66</sup> El uso de un par seno/coseno es idéntico en teoría a la descripción de lugares por medio de un par de coordenadas –  $X$  e  $Y$ . En ambos casos, el par de referencia se conoce como *vectores de base*. En un espacio plano bidimensional, cualquier lugar puede definirse por sus coordenadas  $X$  e  $Y$ . De manera similar, en el campo de la frecuencia, cualquier onda puede ser definida por sus coordenadas seno y coseno.

donde  $f(x)$  es el valor de la función en la posición  $x$ ;  $\omega$  es igual a  $2\pi/T$ , donde  $T$  es el período (la longitud de la serie), y  $k$  es la armónica.<sup>67</sup> Los coeficientes  $a$  y  $b$  están determinados por medio de la Transformación Fourier.

La Transformación de Fourier misma emplea la Fórmula de Euler:

$$e^{-i2\pi ux} = \cos 2\pi ux - i \sin 2\pi ux$$

donde  $i^2$  es  $-1$ , conduciendo a la siguiente formulación para el caso de datos discretos:

$$F(u) = \frac{1}{N} \sum f(x) e^{-ik\omega x}$$

y una fórmula inversa de:

$$f(x) = \sum F(u) e^{ik\omega x}$$

No es necesario que estas expresiones matemáticas se entiendan por completo para darle un uso productivo a la Transformación Fourier. Sin embargo, se puede apreciar del caso anterior que:

1. Estas fórmulas expresan las transformaciones directas e inversas para datos unidimensionales. Simples extensiones hacen que estas transformaciones sean aplicables en datos bidimensionales.

2. La implementación de la Transformación de Fourier usa entradas y salidas de valores complejos. Un número complejo es uno con una parte real y otra imaginaria de la forma  $a+bi$ , donde  $i^2 = -1$ . En el caso aquí considerado, para la *entrada* en el módulo FOURIER, los valores del nivel gris de la imagen conforman la parte real, mientras que la parte imaginaria se establece en cero (esto se es realizado automáticamente por el IDRISI) debido a que no existe. Entonces, la entrada de la Transformación de Fourier es una sola imagen.

3. La *salida* resultante de la transformación progresiva consiste en dos imágenes – una parte real y una imaginaria. La parte real expresa el componente coseno de la serie Fourier, mientras que la parte imaginaria expresa el componente seno. Estas son las amplitudes  $a$  y  $b$  de los componentes coseno y seno expresados en la primera fórmula de esta sección. De éstos se puede determinar la amplitud y la fase de la onda de la siguiente manera:

$$\text{Amplitud} = \sqrt{a^2 + b^2}$$

$$\text{Fase} = \tan^{-1}(b/a)$$

Juntas, las partes real e imaginaria expresan el espectro de frecuencia de una imagen. Mientras que tanto la frecuencia como la fase pueden calcularse fácilmente a partir de estas partes (se puede usar el Calculadora de Imágenes de IDRISI para realizar esto), ninguna se usa comúnmente. Por lo general, el espectro de potencia es calculado y la fase es ignorada.

El espectro de potencia es simplemente el cuadrado de la amplitud. Sin embargo, para fines de un examen visual, se expresa usualmente como una imagen de espectro de potencia de la siguiente forma:

$$\text{Espectro de Potencia} = \ln(1 + \text{amplitud}^2)$$

Esta es la fórmula usada en IDRISI. Entonces, la transformación en sentido normal producida por el módulo FOURIER genera tres salidas – una imagen de parte real, una imagen de parte imaginaria y una imagen de potencia. Estas son comúnmente llamadas imágenes de dominio de frecuencia (en oposición a la imagen original, la cual expresa el dominio espacial).

La intención principal de la Transformación de Fourier es examinar el espectro y modificar sus características antes de la reconstrucción del original por medio de la transformación inversa. El examen del espectro se realiza con la imagen de potencia. No obstante, se implementan modificaciones en las partes real e imaginaria.

Los módulos FILTERFQ, DRAWFILT y FREQDIST se pueden emplear para crear una variedad de filtros para aplicar en las partes real e imaginaria del dominio de frecuencia.

<sup>67</sup> El término “armónica” usado aquí se refiere a la relación de las cantidades cuyos recíprocos están en progresión aritmética (Ej.: 1, 1/2, 1/3, 1/4, etc.); o bien se refiere a puntos, líneas, funciones, etc. que implican dicha relación.



El módulo FOURIER también se puede usar para computar la transformación inversa. En este caso, es necesario suministrar tanto la parte real como la imaginaria del dominio de frecuencia. El resultado es una imagen real – la parte imaginaria se toma como cero, y se descarta.

La verdadera implementación de la Transformación de Fourier en IDRISI es por medio del procedimiento *Transformación Rápida de Fourier* (FFT). Este algoritmo es muy rápido, pero requiere que el tamaño de la imagen (en X e Y) sea potencia de 2 (Ej.: 2, 4, 8, 16, 32, 64, 128, etc.). En los casos en que la imagen es de otro tamaño, los bordes pueden ser rellenados con ceros para hacer que la imagen se ajuste a las dimensiones apropiadas. El módulo ZEROPAD facilita este proceso en el IDRISI.

El Análisis de Fourier supone que la imagen misma es infinitamente periódica. Por ello, se supone que la imagen se repite eternamente en X e Y. El efecto es similar a doblar la imagen en X e Y de manera tal que la última columna toque la primera y la última fila toque la primera fila. Si los valores grises en estos extremos son bastante diferentes, su yuxtaposición producirá componentes falsos de frecuencia alta en la transformación. Esto puede ser mitigado con un relleno de ceros en los bordes. Por lo tanto, el relleno de cero es, a menudo, bastante apreciado.

## Usando el Análisis de Fourier en IDRISI

Reuniendo y extendiendo la información anterior, los siguientes procedimientos son típicos del Análisis de Fourier en IDRISI.

1. Preparar la imagen para el análisis. Tanto las filas como las columnas deben ser potencia de 2. Sin embargo, no es necesario que sean iguales. Entonces, por ejemplo, una imagen original de 200 columnas y 500 filas deberá ser rellenada para ser una imagen de 256 columnas y 512 filas. Para hacer esto, use el módulo ZEROPAD de IDRISI. Si la imagen original ya tiene filas y columnas que son potencia de 2, este paso se puede omitir.

2. Ejecutar FOURIER con la transformación en sentido normal usando como entrada la imagen preparada en el paso 1. La imagen puede contener datos byte, enteros o reales – el tipo de datos no es importante. FOURIER producirá tres salidas – una imagen de parte real, una imagen de parte imaginaria y una imagen de espectro de potencia. La última de estas está preparada para el análisis visual, mientras que las dos primeras son usadas para el análisis numérico.

3. Examinar la imagen de espectro de potencia y diseñar un filtro (tema desarrollado con más detalle en la próxima sección). Para crear el filtro, use el módulo FREQDIST (seguido por RECLASS o bien FUZZY), el módulo FILTERFQ o el módulo DRAWFILT.

4. Aplicar el filtro a las imágenes de parte real e imaginaria creadas en el paso 2. Generalmente, esto se realiza a través de una multiplicación usando el módulo OVERLAY.

5. Ejecutar nuevamente FOURIER y usar las partes real e imaginaria modificadas como entrada para la transformación inversa. El resultado es la imagen reconstruida. Observe que esta producción siempre es una imagen de números reales que puede convertirse en la forma byte o entera si se los desea (y si el rango de valores lo permite). También se debe suministrar la imagen original que fue enviada a la transformación en sentido normal. Esta imagen provee información del sistema de referencia. Si el relleno de ceros fuese agregado antes de la transformación en sentido normal, entonces esa imagen (con el relleno de ceros) se daría aquí como la imagen original.

6. Si se agrega el relleno de ceros, use WINDOW para extraer la imagen y colocarla en un nuevo archivo.

## Interpretando Imágenes de Dominio de Frecuencia

Cuando se las trata por primera vez, las imágenes de dominio de frecuencia parecen muy extrañas. Es más, es difícil creer que contienen la información requerida para restaurar completamente toda la imagen de dominio espacial. No obstante, los píxeles de las imágenes de parte real e imaginaria contienen un registro completo de las ondas sinusoidales que forman la imagen cuando son combinadas. En estas imágenes, al igual que en la imagen de espectro de potencia, la posición de cada pixel en relación con la celda central indica la frecuencia de la onda, mientras que el valor del pixel indica la amplitud.

Para fines de análisis visual siempre se usa la imagen de espectro de potencia debido a que contiene un registro visualmente mejorado de la amplitud de las ondas componentes.<sup>68</sup> Dentro de esta imagen, cada pixel representa una

frecuencia de onda diferente, con la única excepción del pixel central ubicado en las  $(\text{columnas}/2)$  y  $((\text{filas}/2) - 1)$ . Este pixel representa una frecuencia de 0 – una expresión del nivel promedio de grises de la imagen, similar en teoría a una ordenada al origen en el análisis de regresión.

Los pixeles de la derecha inmediata  $((\text{columnas}/2) + 1)$  y de arriba  $(\text{filas}/2)$  representan las ondas de frecuencia más baja (longitud de onda más larga) en la composición, con una frecuencia de una onda completa en toda la extensión de la imagen, es decir, una frecuencia de  $(1/(\text{nd}))$  donde  $n$  = número de filas o columnas y  $d$  = resolución de pixeles. Entonces, en una imagen de 512 columnas por 512 filas, y celdas de 30 metros, el pixel de la derecha inmediata o arriba del centro representa una frecuencia de  $(512*30))=1/15,360$  metros. De manera similar, el segundo pixel hacia la derecha o arriba del centro representa una frecuencia de  $(2/(\text{nd}))=(2/(512*30))=1/7.680$  metros. Luego, el tercer pixel hacia la derecha o arriba del centro representa una frecuencia de  $(3/(\text{nd}))=(3/(512*30))=1/5.120$  metros. Esta lógica continúa hasta los bordes del extremo derecho y superior, los cuales tendrían una frecuencia de  $(255/(\text{nd}))=(255/(512*30))=1/60,24$  metros. Este último valor es sólo un déficit de la frecuencia limitante de  $(256/(\text{nd}))=(256/(512*30))=1/60$  metros. Esta frecuencia limitante es la *frecuencia Nyquist*, y representa la longitud de onda más corta que pueda describirse por medio de pixeles con una resolución dada. En este ejemplo, la onda más corta se repite cada 60 metros.

El cuadrante del extremo superior derecho describe ondas con frecuencias positivas en X e Y. Todos los demás cuadrantes contienen al menos una dimensión que describe ondas negativas. Por ejemplo, el cuadrante del extremo inferior izquierdo describe frecuencias que son negativas tanto en X como en Y. Las frecuencias negativas son una consecuencia del hecho de que el Análisis de Fourier supone que la información analizada es infinitamente periódica.

Esto se logra imaginando que la imagen original puede ser doblada en forma de cilindro en X e Y para que la primera y la última columna se unan una con otra y para que la fila superior y la inferior también se unan de manera similar. Tenga en cuenta además que los cuadrantes del extremo superior derecho y del extremo inferior izquierdo son imágenes espejo de cada uno como lo son los cuadrantes del extremo inferior derecho y del extremo superior izquierdo. Esta simetría nace del hecho de que los datos de entrada son imágenes de números reales y no de números complejos.

Finalmente, tenga en cuenta que la primera columna y la última fila (y la última columna y la primera fila) representan la amplitud y la potencia de las ondas en la frecuencia Nyquist tanto para la frecuencia positiva como para la negativa – es decir, usando el ejemplo anterior,  $(256/(\text{nd}))=(256/(512*30))=1/60$  metros y  $(-256/(\text{nd}))=(-256/(512*30))=-1/60$  metros. La razón por la cual éstas representan tanto la frecuencia positiva como la negativa se relaciona con el doblaje cilíndrico indicado arriba que es necesario para crear una forma infinitamente periódica.

Dada la lógica anterior en la estructura de las imágenes de amplitud y de espectro de potencia, se pueden apreciar varios puntos claves:

1. Las imágenes de amplitud y de espectro de potencia tienen un carácter radial alrededor del punto central que representa la frecuencia cero.
2. Los elementos de ruido son bastante parecidos a características lineales o puntuales aberrantes en el espectro de potencia. Los elementos de ruido lineales aparecen en un ángulo de 90 grados en la imagen de espectro de potencia a su dirección de dominio espacial, Ej.: el rayado vertical en la imagen original produce elementos horizontales en la imagen de espectro de potencia.
3. Estos elementos de ruido pueden ser filtrados al reducir sus amplitudes a 0 en el dominio de frecuencia y luego se hace la transformación inversa.

## Diseño del Filtro de Dominio de Frecuencia

La Figura 16-6a muestra un ejemplo de una imagen con un severo bandeo horizontal, mientras que la Figura 16-6b muestra su espectro de potencia creado por FOURIER. La Figura 16-6c muestra un filtro notch (corte en forma de V) creado con FILTERFQ. Tanto la parte real como la imaginaria de la transformación del dominio de frecuencia luego fueron multiplicadas por este filtro para eliminar estas longitudes de onda (reducir sus amplitudes a 0).

<sup>68</sup> La información de la fase no es importante para el análisis visual, y se pierde en la producción de la imagen de espectro de potencia. No obstante, todas las manipulaciones matemáticas son llevadas a cabo en las imágenes de parte real y de parte imaginaria, las cuales, juntas, contienen amplitud información completa de la amplitud y de la fase.

Finalmente, la Figura 15-6d muestra el resultado de la aplicación de la transformación inversa sobre las imágenes de parte real y de parte imaginaria.



La Figura16-6 a-d: Aplicación de la Transformación de Fourier para eliminar el bandeo en una imagen. a: (arriba, izquierda) muestra la imagen original con bandeo horizontal; b: (arriba, centro) muestra su espectro de potencia creado con el módulo FOURIER. Observe la línea vertical en el centro asociada con el bandeo horizontal en la imagen original; c: (arriba, derecha) muestra un filtro notch creado con FILTERFQ; d: (abajo, izquierda) muestra el resultado de la aplicación del filtro notch y de la subsiguiente aplicación de la Transformación de Fourier inversa.

IDRISI proporciona una variedad de utilidades para desarrollar filtros de dominios de frecuencia. Comúnmente uno usaría FILTERFQ, que ofrece 26 filtros, cada uno de los cuales puede ser controlado para las características específicas de los datos manipulados y también para la finalidad específica del filtro. El segundo módulo más usado es el DRAWFILT, una herramienta interactiva de desarrollo de filtros con la que uno dibuja literalmente las áreas (es decir, frecuencias) que deben ser eliminadas. Finalmente, para una mayor flexibilidad aún, IDRISI ofrece un módulo llamado FREQDIST. Como lo indica el nombre, este módulo crea una imagen de distancia de frecuencia (medida desde el punto central del espectro de potencia). Esta luego puede usarse como la entrada básica para una variedad de herramientas modeladoras de filtros como RECLASS o FUZZY. La imagen de distancia de frecuencia también puede ser enviada a SURFACE para crear una imagen de aspecto que luego puede ser modelada por RECLASS o FUZZY para crear filtros direccionales.

Sin importar cómo es creado el filtro, la aplicación de ese filtro se logra de la misma manera en todos los casos – por simple multiplicación, usando OVERLAY con las imágenes de parte real y de parte imaginaria. La multiplicación en el dominio de frecuencia es equivalente a la convulsión en el dominio espacial.

## Referencias

Las referencias para el filtro de dominio de frecuencia incluyen:

Gonzalez, R.C., y Woods, R.E., 1992. *Digital Image Processing* , Addison-Wesley, Reading, Massachusetts.

Mather, P., 1987. *Computer Processing of Remotely Sensed Images*, John Wiley y Sons, Nueva York.

Jensen, J.R., 1996. *Introductory Digital Image Processing: A Remote Sensing Perspective* , Prentice Hall, Upper Saddle River, NJ.

# CAPÍTULO 17 - Clasificación de las Imágenes de Sensores Remotos

## Introducción

La clasificación es el proceso de desarrollar mapas interpretados de imágenes de sensores remotos. Como consecuencia, la clasificación es tal vez el aspecto más importante del procesamiento de imágenes para SIG. Tradicionalmente, la clasificación se lograba a través de la interpretación visual de características y de la delineación manual de sus límites. Sin embargo, con el advenimiento de las computadoras y del tratamiento digital de imágenes, se ha prestado atención en el uso de la interpretación asistida por computadora. Aunque el ojo humano todavía brinda un conjunto superior de capacidades para el proceso de clasificación, la velocidad y la consistencia de los procedimientos digitales los hacen muy atractivos. Como consecuencia, la mayoría de los proyectos de clasificación en la actualidad emplean procedimientos de clasificación digital, guiados por la interpretación humana.

## Clasificación Supervisada versus No Clasificada

Como se indicó en el capítulo **Introducción a los Sensores Remotos y al Procesamiento de Imágenes**, existen dos enfoques básicos para el proceso de clasificación: clasificación supervisada y no supervisada. Con la clasificación supervisada, uno provee una descripción estadística del modo en el que se espera que ciertas coberturas terrestres aparezcan en la imagen, y luego se usa un procedimiento (conocido como un *clasificador*) para evaluar la probabilidad de que cada pixel pertenezca a una de estas clases. Con la clasificación no supervisada, se utiliza un enfoque muy diferente.

Aquí se emplea otro tipo de clasificación para descubrir en la imagen patrones de ocurrencia común y de reflectancia distintiva, con la suposición de que éstos representan clases importantes de cobertura terrestre. Luego, el analista determina la identidad de cada clase por medio de una combinación de experiencia y verdad de terreno (es decir, visita el área de estudio y observa los verdaderos tipos de cobertura).

En ambos casos, el proceso de clasificación puede interpretarse como uno que determina el grupo al que cada pixel pertenece. En el caso de la clasificación supervisada, los grupos se conocen (o se supone que se conocen) antes de comenzar el proceso. La clasificación es, por lo tanto, un proceso de toma de decisión basado en información disponible.

Con la clasificación no supervisada, en cambio, las clases se desconocen al comienzo. Entonces, el proceso no es tanto uno de toma de decisión en sí, sino en realidad uno de segmentación.

## Patrones de Respuesta Espectral versus Firmas

Como se explicó en el capítulo **Introducción a los Sensores Remotos y al Procesamiento de Imágenes**, cada material interactúa con energía electromagnética al reflejar, absorber o transmitir la misma. La naturaleza exacta de esa interacción varía de una longitud de onda a la siguiente – un patrón conocido como *Patrón de Respuesta Espectral* (SRP). La base para la clasificación es, entonces, encontrar algún área del espectro electromagnético en donde la naturaleza de esa interacción sea distintivamente diferente de la de otros materiales que aparecen en la imagen. Muchos se refieren a esto como firma – un patrón de respuesta espectral característico de ese material. Sin embargo, en la práctica, la determinación de firmas consistentemente diferentes es difícil de lograr por las siguientes razones:

- la mayoría de los tipos de vegetación no poseen patrones de respuesta espectral consistentes – los cambios fenológicos durante la estación de crecimiento puede producir a firmas altamente variables.
- los cambios en la iluminación (debido a las pendientes o al momento del año) y las variaciones en la humedad también pueden producir patrones de respuesta espectral significativamente diferentes.
- la mayoría de las coberturas terrestres consisten en mezclas de características elementales que son percibidas como un solo pixel. Por ejemplo, un cultivo dispuesto en filas como el maíz en realidad contiene una mezcla de planta y suelo según lo percibe el satélite. De manera similar, un pixel puede contener una mezcla de especies coníferas y caducifolias en un área boscosa.
- para un sensor dado, no hay garantía de que las longitudes de onda en las que éste realiza las percepciones sea

igual a aquellas en las que el material es más distintivo. Actualmente, los sensores multiespectrales examinan varias áreas muy importantes del espectro, particularmente para la diferenciación de la vegetación. No obstante, las áreas utilizables no examinadas sobrepasan aquellas examinadas, y muchas de las longitudes de onda que podrían distinguir potencialmente numerosos tipos de roca, por ejemplo, no son usualmente examinadas.

Como resultado de estos problemas, ha habido una fuerte orientación dentro de la comunidad de especialistas en sensores remotos para desarrollar firmas con referencia a ejemplos específicos dentro de la imagen a clasificar en lugar de basarse en el uso de bibliotecas más generales de patrones de respuesta espectral característicos. Estos ejemplos muy específicos se denominan *sitios de entrenamiento*, y se llaman así porque son usados para entrenar al clasificador sobre qué buscar. Al elegir ejemplos de la imagen misma (usualmente confirmados por una visita de verdad de terreno), uno desarrolla firmas específicas a las longitudes de onda disponibles. Además, se evitan problemas de variaciones tanto en el ángulo del cenit solar como en la etapa de la estación de crecimiento. Uno también puede elegir ejemplos característicos de las numerosas mezclas de clases de cobertura existentes.

Más allá de este enfoque bastante pragmático de la clasificación, sigue siendo en gran medida un problema de decisión. Le ordenamos al proceso crear una clasificación definitiva en presencia de una variación considerable. Por ejemplo, a pesar de las diferencias en la etapa de crecimiento, del suelo de fondo y la presencia de cultivos consociados, le ordenamos al proceso destilar todas las variaciones de granos de maíz en una sola clase de maíz.

Recientemente, sin embargo, se ha prestado interés en relajar este enfoque tradicional en dos áreas, ambas fuertemente representadas en el IDRISI. La primera es el desarrollo de clasificadores *blandos*, mientras que la segunda extiende la lógica de la percepción multiespectral a la *percepción hiperespectral*.

## Clasificadores Rígidos versus Blandos

Los clasificadores tradicionales pueden llamarse clasificadores *rígidos* ya que producen una decisión rígida acerca de la identidad de cada pixel. Al contrario, los clasificadores *blandos* expresan el grado en el que un pixel pertenece a cada una de las clases consideradas. Entonces, por ejemplo, en lugar de decidir si un pixel es bosque de caducifolias o de coníferas, se indica que su grado de pertenencia en la clase caducifolia es de 0,43 y en la conífera es de 0,57 (un clasificador rígido concluiría que es de clase conífera). Uno de los motivos para usar un clasificador blando es determinar la mezcla de clases de cobertura terrestre presentes. Si podríamos suponer que estas dos clases fuesen las únicas presentes, sería razonable concluir que el pixel contiene 43% de cobertura caducifolia y 57% de conífera. Tal conclusión se conoce como *clasificación sub-pixel*.

Un segundo motivo para usar un clasificador blando es medir y registrar la fuerza de la evidencia en apoyo a la mejor conclusión que pueda hacerse. IDRISI introduce clasificadores blandos especiales que permiten determinar, por ejemplo, que la evidencia para caducifolias se encuentra presente en un nivel de 0,26; para coníferas en un 0,19 y para algún tipo desconocido en un 0,55. Esto inmediatamente sugeriría que mientras el pixel posee algunas similitudes con nuestros sitios de entrenamiento para estas dos clases, en realidad éste pertenece a algún tipo que aún no hemos identificado.

Un tercer motivo para emplear clasificadores blandos está relacionado con el uso de capas de datos y modelos SIG para suplementar la información usada para alcanzar una decisión final. Por ejemplo, uno puede extraer un mapa de la probabilidad de que cada pixel pertenezca a una clase de cobertura terrestre residencial a partir de datos espectrales.

Luego puede usarse una capa de datos SIG de caminos para crear un mapa de la distancia a los caminos, del cual podría deducirse la probabilidad de *no* ser residencial (las áreas lejos de los caminos tienen poca probabilidad de ser residenciales). Estas dos líneas de evidencia luego pueden combinarse para producir una declaración más fuerte de la probabilidad de que esta clase exista. Una decisión rígida final puede lograrse subsecuentemente al enviar las declaraciones individuales de pertenencia de clase a un *endurecedor* apropiado – un proceso de decisión que elige la alternativa más probable.

## Clasificadores Multiespectrales versus Hiperespectrales

El segundo nuevo desarrollo importante en clasificadores es el uso de datos *hiperespectrales*. Hoy, la mayoría de los sensores se denominan *multiespectrales* debido a que perciben energía electromagnética en más de un área del espectro al mismo tiempo. Cada una de estas áreas se llama banda y está representada por una sola imagen monocromática. Por ejemplo, el sistema sensor LANDSAT Thematic Mapper (TM) visualiza siete bandas

simultáneas en las áreas de longitud de onda azul (Banda 1), verde (Banda 2), roja (Banda 3), infrarroja cercana (Banda 4), infrarroja media (Banda 5 y 7) e infrarroja termal (Banda 6). Los sensores hiperspectrales en realidad no son diferentes en concepto, excepto que visualizan muchas bandas finamente definidas. Por ejemplo, el sistema experimental AVIRIS desarrollado por Jet Propulsion Laboratory (JPL) visualiza 224 bandas sobre un rango de longitud de banda en cierta forma parecido al sensor TM.

De manera similar, el sistema EOS-MODIS, lanzado en diciembre de 1999, extiende 36 bandas esencialmente sobre el mismo rango que el cubierto por las cinco bandas del sistema correspondiente AVHRR de la serie de satélites NOAA.

Es tentador pensar que más es mejor – es decir, un mayor número y una resolución espectral más alta de las bandas hiperspectrales naturalmente conducen a mejores clasificaciones. Sin embargo, este no es necesariamente el caso. Las imágenes hiperspectrales mayormente están correlacionadas en gran medida con otras bandas de longitud de onda similar. Entonces, uno debe procesar una cantidad de datos bastante incrementada (que afecte el nivel de sofisticación del algoritmo del clasificador) sin una ganancia correspondiente de información. El verdadero beneficio de las imágenes hiperspectrales se obtiene de la habilidad para prever características de absorción muy delgada (regiones espectrales que exhiben una fuerte absorción de materiales específicos) en una resolución alta. Esto ha logrado un éxito valioso mayormente en el contexto de las aplicaciones geológicas. Por ejemplo, recientes misiones extraterrestres como las misiones Mars Survivor, Galileo y Cassini de la NASA llevan sensores hiperspectrales con el propósito de realizar mapeos minerales. La alta resolución espectral de estos sistemas provee la habilidad para medir patrones de absorción mineral con gran precisión, originando también la habilidad para mapear tanto la presencia como la abundancia de materiales superficiales. La clasificación hiperspectral aún es bastante nueva y de carácter efectivamente experimental. IDRISI incluye una serie de procedimientos para trabajar con estos datos.

## Resumen del Enfoque en este Capítulo

En las siguientes secciones, cubriremos la lógica y la estrategia generales para usar cuando se trabaja con los módulos de clasificación en el sistema IDRISI. Se pueden hallar notas detalladas sobre el uso de cada módulo en el Sistema de Ayuda on-line. Más aún, hay ejemplos en forma de ejercicios en el manual **Tutorial**.

## Clasificación Supervisada

### Lógica General

Existe una lógica consistente para todas las rutinas de clasificación del IDRISI, sin importar si son clasificadores rígidos o blandos. Además, hay una secuencia básica de operaciones que debe seguirse sin importar cuál de los clasificadores está siendo usado. Esta secuencia se describe aquí. El manual **Tutorial** también contiene ejemplos elaborados de este proceso.

### 1. Definir los Sitios de Entrenamiento

El primer paso al llevar a cabo una clasificación supervisada es definir las áreas que serán usadas como sitios de entrenamiento para cada clase de cobertura terrestre. Generalmente, esto se realiza usando la utilidad de digitalización en pantalla como se explicó en el capítulo **Usando el IDRISI**. Debe elegir una banda con contraste alto (como una banda infrarroja cercana) o un compuesto de colores para emplear en la digitalización. Luego despliegue la imagen sobre la pantalla (utilice la autoescala, si es necesario, para obtener un buen contraste) y use la utilidad de digitalización en pantalla para crear uno o más archivos vectoriales de los polígonos de sitios de entrenamiento – esquemas vectoriales de las áreas de sitios de entrenamiento.<sup>69</sup>

<sup>69</sup> IDRISI ofrece dos procedimientos para la digitalización de polígonos de sitios de entrenamiento. Con el procedimiento por defecto, uno digitaliza un grupo de puntos que forman el límite del polígono del sitio de entrenamiento. El segundo procedimiento crea el polígono al agregar todos los píxeles contiguos que rodean un punto designado que se encuentra dentro de una tolerancia especificada de las características espectrales del píxel central. Esto se denomina un polígono de inundación porque es análogo al concepto del agua que fluye hacia fuera del punto designado. Además notará que con esta opción se puede especificar una distancia máxima para limitar hasta dónde se expandirá este procedimiento de crecimiento. Tenga en cuenta que el sistema además permite definir sitios de entrenamiento por medio de una imagen raster. En algunos casos, tiene sentido definir estas ubicaciones por referencia directa a las ubicaciones terrestres (como por medio de ubicaciones puntuales obtenidas con un GPS). Sin embargo, esto requiere un georeferenciamiento previo de la imagen muy exacto, y una confianza en que los errores de posición no incluirán píxeles no deseados en los sitios de entrenamiento. Algunos procedimientos de georeferenciamiento también alteran las características de la imagen que pueden ser no deseadas.

Es por estas razones que la clasificación comúnmente se lleva a cabo en imágenes no georeferenciadas usando la digitalización en pantalla de sitios de entrenamiento. La imagen clasificada final es georeferenciada en un paso posterior.

Las buenas ubicaciones de sitios de entrenamiento usualmente son aquellas con una muestra de la clase de información tan pura como sea posible. Por ejemplo, si Ud. eligiese definir un sitio de bosque caducifolio, sería importante seleccionar un área que no esté mezclada con coníferas y que tenga poco suelo de fondo o vegetación visible bajo los árboles.

Cuando digitaliza sitios de entrenamiento, también debe evitar incluir cualquier pixel que pertenezca a coberturas terrestres adyacentes. Esto se logra más fácilmente si le aplica un zoom de aumento al área antes de digitalizar ese sitio.

Por lo general, se debe tratar de digitalizar los pixeles suficientes de manera que haya al menos 10 veces la cantidad de pixeles por cada clase de entrenamiento como bandas en la imagen a clasificar. Entonces, para una imagen LANDSAT TM con siete bandas, se deben tener al menos 70 pixeles por clase de entrenamiento (una cantidad mayor a esta no es difícil de lograr y está recomendada – mientras más cantidad, mejor). Si esto es difícil de lograr con un solo sitio, simplemente digitalice más de un sitio de entrenamiento para esa clase. La utilidad de digitalización en pantalla requiere que Ud. disponga un identificador entero por cada característica. Entonces, para digitalizar más de un sitio de entrenamiento para una clase de cobertura terrestre, simplemente asigne el mismo identificador a cada ejemplo. Hacer una lista de ID's (identificadores) y sus clases de información correspondientes puede resultar muy útil.

Finalmente, observe que no se requiere que todos los sitios de entrenamiento estén incluidos en un solo archivo vectorial creado con la utilidad de digitalización en pantalla. Ud. puede crear un solo archivo vectorial por cada clase de información si lo desea. Esto simplemente necesitará que se lleve a cabo el paso de desarrollo de firmas por cada uno de estos archivos. Alternativamente, Ud. puede enlazar estos archivos vectoriales en un solo archivo vectorial con CONCAT o puede rasterizar todos los archivos vectoriales en una sola imagen raster y desarrollar las firmas a partir de ese solo archivo vectorial o imagen raster.

## 2. Extraer Firmas

Después de haber digitalizado las áreas de los sitios de entrenamiento, el próximo paso será crear caracterizaciones estadísticas de cada clase informativa. En el IDRISI, estas se llaman *firmas*. Usualmente, esto se logra con el módulo MAKESIG.<sup>70</sup> MAKESIG le pedirá el nombre del archivo vectorial o raster que contiene los sitios de entrenamiento para una o más clases informativas, y las bandas para usar en el desarrollo de firmas. Luego le pedirá un nombre por cada una de las clases incluidas. Estos nombres deben ser adecuados como nombres de archivos de IDRISI ya que serán usados para crear archivos de firmas (extensión .sig) para cada clase informativa. Si empleó más de un archivo vectorial para almacenar sus polígonos de sitios de entrenamiento, ejecute MAKESIG para cada uno de estos archivos. Su meta es crear un archivo SIG por cada clase informativa.

Los archivos SIG contienen una variedad de información sobre las clases de cobertura terrestre que describen.<sup>71</sup> Éstos incluyen los nombres de las bandas de imágenes de las cuales se ha extraído la caracterización estadística, los valores mínimo, máximo y medio de cada banda, y la matriz de varianza/covarianza completa asociada con ese grupo de bandas de imagen multispectral para esa clase. Para examinar los contenidos de este archivo en detalle, use SIGCOMP. Tenga en cuenta también que el módulo SEPSIG se puede emplear para evaluar la capacidad distintiva de su grupo de firmas.

## 3. Clasificar la Imagen

El tercer (y a veces el último) paso es clasificar la imagen. Esto se puede realizar con cualquiera de los clasificadores rígidos o blandos descritos a continuación. Obviamente existen muchas opciones. Sin embargo, aquí hay algunos puntos a tener en cuenta:

- el procedimiento paralelepípedo (el módulo PIPED) solo se incluye por razones pedagógicas. Generalmente, no debería usarse.
- cuando se sabe que los sitios de entrenamiento son fuertes (es decir, bien definidos con un tamaño de muestra grande), se debe emplear el procedimiento MAXLIKE. No obstante, si existen inquietudes acerca de la calidad de los sitios de entrenamiento (particularmente su uniformidad), debe usarse el procedimiento MINDIST con distancias estandarizadas.

<sup>70</sup> El módulo FUZSIG ofrece una lógica interesante, aunque bastante diferente, para extraer firmas de sitios de entrenamiento impuros. Esto se discute más adelante con mayor profundidad en la sección sobre firmas difusas. El módulo ENDSIG también crea firmas para usar con el clasificador UNMIX.

<sup>71</sup> Cada archivo SIG además posee un archivo SPF correspondiente que contiene los verdaderos valores de los pixeles usados para crear el archivo SIG. Éste solo es empleado por HISTO para visualizar los histogramas de firmas.

El módulo MINDIST con la opción de distancias estandarizadas es un clasificador muy fuerte, y es menos susceptible que el MAXLIKE ante problemas en los sitios de entrenamiento.

- el Clasificador Fisher puede ejecutarse excepcionalmente bien cuando no hay áreas esenciales de clases desconocidas y cuando los sitios de entrenamiento son en gran medida representativos de sus clases informativas.

- para la clasificación subpixel (es decir, análisis de componentes mixtos), use uno de los clasificadores blandos UNMIX.

Los otros clasificadores blandos son mayormente empleados como parte de un proceso de Evaluación de la Clasificación en Proceso (In-Process Classification Assessment-IPCA) (ver el paso siguiente). También son utilizados en los casos donde la modelación SIG se considera como una parte significativa del proceso de clasificación.

- cuando una nueva área se tiene en cuenta primero para la clasificación, considere usar el CLUSTER como un precursor para la selección de sitios de entrenamiento.

#### 4. Evaluación de la Clasificación en Proceso (IPCA)

La preocupación clave que enfrenta un analista en la clasificación es la exactitud del procedimiento de clasificación. Tradicionalmente, esto se ha tratado a través de una evaluación de exactitud, como la que se describe en una sección a continuación. No obstante, con los clasificadores blandos en el IDRISI, es posible un procedimiento de Evaluación de la Clasificación en Proceso (IPCA). Como lo implica el nombre, esta es una evaluación que se lleva a cabo como parte de un proceso iterativo de mejoramiento de la clasificación, y por lo general involucra la comparación de un grupo de resultados clasificados.

Hoy en día, la IPCA es en gran medida un procedimiento experimental, y requiere conocimiento de los procedimientos de clasificación blanda que se discuten más adelante en este capítulo. Sin embargo, el concepto es bastante simple. El proceso implica una comparación de los resultados de un clasificador rígido y su correspondiente clasificador blando. Por ejemplo, para el clasificador rígido MINDIST, se usaría el clasificador blando FUZCLASS (opción no normalizada); mientras que para el clasificador rígido MAXLIKE, se usaría el clasificador blando BELCLASS. Cada uno de estos clasificadores blandos produce una imagen de *incertidumbre de la clasificación* que expresa el grado de dificultad que tiene el clasificador al determinar una sola clase para asignar a un pixel. Las áreas de incertidumbre alta son obviamente aquellas que necesitan trabajo en términos de un refinamiento de la clasificación.

Existen dos razones básicas para la incertidumbre alta por parte de un clasificador. La primera es que el pixel contenga una mezcla de categorías más básicas y entonces no pueda ser asignado fácilmente a una sola interpretación. La otra es que el pixel no se parezca a ninguna de las firmas establecidas.<sup>72</sup>

En el caso en que la incertidumbre es alta debido a la presencia de una mezcla de clases, existen dos posibilidades. Los datos de entrenamiento son pobres, y por lo tanto no son adecuadamente distintivos para separar estas dos clases, o bien la clase mixta verdaderamente existe en la resolución del análisis. Las mezclas importantes deben examinarse con cuidado, preferentemente con una visita al terreno para solucionar el problema. Luego considere desarrollar nuevos sitios de entrenamiento para las clases confundidas, o bien considere agregar una nueva clase, con un sitio de entrenamiento apropiado, para representar la mezcla indistinguible.

Observe que en los casos en que el último clasificador es MAXLIKE, el clasificador MAXSET (como se describe en la sección sobre Clasificación No Supervisada más adelante) puede usarse como un medio muy eficiente para identificar mezclas en combinación con la imagen de incertidumbre de la clasificación del BELCLASS.

En los casos en que la incertidumbre es alta porque no hay una coincidencia fuerte con ninguno de los sitios de entrenamiento fijados, debe considerarse una visita de verdad de terreno para determinar la identidad de la clase perdida. Esta clase luego debe ser agregada con un sitio de entrenamiento apropiado.

Claramente, la finalidad de la IPCA es identificar dónde ocurren los problemas en el proceso de clasificación y rectificarlos a través de un proceso iterativo. El refinamiento progresivo o la redefinición de los sitios de entrenamiento y la subsiguiente reclasificación de la imagen continúan con más evaluaciones.

---

<sup>72</sup> Esta segunda posibilidad no existe si uno emplea el módulo BAYCLASS o el FUZCLASS con salida normalizada. Ambos de estos procedimientos de clasificación blanda suponen que las clases consideradas son las únicas posibles. Es por esta razón que el procedimiento BELCLASS se recomienda para la comparación con MAXLIKE y el FUZCLASS con la salida no normalizada se recomienda para la comparación con MINDIST.



## 5. Generalización

El quinto paso es opcional y frecuentemente omitido. Luego de la clasificación, puede haber muchos casos de píxeles aislados que pertenecen a una clase que se diferencia de la mayoría que la rodea. Esta puede ser una descripción exacta de la realidad, aunque para propósitos de mapeo, una operación muy común posterior al procesamiento es generalizar la imagen y eliminar estos píxeles aislados.

Esto se realiza aplicando un filtro de modo al resultado (usando el módulo FILTER de IDRISI). El filtro de modo reemplaza cada píxel por la clase de mayor ocurrencia dentro de una ventana de 3x3 alrededor de cada píxel. Esto efectivamente elimina los parches de clases de uno o unos pocos píxeles y los reemplaza por la clase vecina más común. Utilice esta operación con cuidado – es una generalización que verdaderamente altera el resultado clasificado.

## 6. Evaluación de la Exactitud

El paso final del proceso de clasificación usualmente involucra una evaluación de la exactitud. Tradicionalmente, esto se realiza al generar un grupo aleatorio de ubicaciones (usando la opción aleatoria estratificada del módulo SAMPLE de IDRISI) para hacer una visita al terreno para verificar el tipo de cobertura terrestre verdadero. Luego, un archivo simple de valores registra la clase de cobertura terrestre verdadera (por medio de su número de índice entero) para cada una de estas ubicaciones. Este archivo de valores luego es usado con el archivo vectorial de ubicaciones puntuales para crear una imagen raster de las clases verdaderas halladas en las ubicaciones examinadas. Esta imagen raster luego es comparada con el mapa clasificado usando ERRMAT. Este módulo tabula la relación entre las clases de cobertura terrestre verdaderas y las clases como son mapeadas. Además tabula los *errores de omisión* y los *errores de comisión* así como también el error proporcional total.

El tamaño de la muestra ( $n$ ) para usar en la evaluación de la exactitud puede estimarse con la siguiente fórmula:

$$n = z^2 pq / e^2$$

donde

$z$  es el valor estándar requerido para el nivel deseado de confianza (Ej.: 1,96 por 95% de confianza; 2,58 por 99%; etc.) en la evaluación

$e$  es el intervalo de confianza deseado (Ej.: 0,01 por  $\pm 10\%$ )

$p$  es el error proporcional *a priori*, y


$$q = 1 - p$$

## Clasificadores Rígidos

Los clasificadores rígidos se llaman así porque todos alcanzan una decisión rígida (es decir, inequívoca) acerca de la clase a la que cada píxel pertenece. Todos se basan en una lógica que describe la posición esperada de una clase (basada en datos de sitios de entrenamiento) en lo que se conoce como *espacio de banda*, y luego miden la posición de cada píxel para clasificarlo en el mismo espacio de banda relativo a estas posiciones de clases. Desde esta perspectiva, el clasificador más fácil de entender es el procedimiento MINDIST.

### Distancia Mínima a la Media


El módulo MINDIST implementa un clasificador de *Distancia Mínima a la Media*. Basándose en los datos de sitios de entrenamiento, MINDIST caracteriza cada clase por su posición media sobre cada banda. Por ejemplo, si solo dos bandas fueran usadas, la Figura 17-1 caracterizaría las posiciones de un grupo de clases conocidas como están determinadas por los datos de sitios de entrenamiento.



**Figura 17-1**


Aquí cada eje indica la reflectancia sobre una de las bandas. Entonces, al usar la reflectancia media sobre estas bandas como coordenadas X e Y, la posición de la media puede colocarse en este espacio de banda. De manera similar, la posición de cualquier pixel no clasificado también se puede colocar en este espacio usando su reflectancia sobre las dos bandas como sus coordenadas.

Para clasificar un pixel desconocido, MINDIST examina entonces la distancia desde esa pixel hasta cada clase y le asigna la identidad de la clase más cercana. Por ejemplo, al pixel no clasificado que se muestra en la Figura 17-2 se le asignaría la clase “arena” ya que ésta es la clase media más cercana al pixel.



**Figura 17-2**

A pesar de la simplicidad de este enfoque, en realidad se desempeña bastante bien. Es razonablemente rápido y puede emplear un umbral de distancia máxima que permite que cualquier pixel que sea diferente a cualquier clase dada no sea clasificado. Sin embargo, el enfoque sufre problemas relacionados con la variabilidad de firmas. Al caracterizar cada clase por su reflectancia de banda media solamente, no posee conocimiento alguno del hecho de que algunas clases son inherentemente más variables que otras. Esto, a su vez, puede conducir a una clasificación errónea. Por ejemplo, considere el caso de una clase caducifolia altamente variable y una clase de arena muy consistente al clasificar el pixel no clasificado en la Figura 17-3.



**Figura 17-3**

Los círculos en esta figura ilustran la variabilidad de cada una de estas dos clases. Si asumimos que estos círculos representan una distancia de dos desviaciones estándar a la media, podemos ver que el píxel se encuentra dentro del rango de variabilidad de la categoría caducifolia, y fuera del rango de la arena. Sin embargo, también podemos ver que se encuentra más cerca de la media para la arena. En este caso, el clasificador clasificaría erróneamente el píxel como arena cuando en realidad debería considerarse como bosque caducifolio.

Este problema de variabilidad puede resolverse si el concepto de la distancia se cambia al de los valores estándar. Esta transformación se puede lograr con la siguiente ecuación:


$$\text{distancia estandarizada} = (\text{distancia original} - \text{media}) / \text{desviación estándar}$$

El procedimiento MINDIST de IDRISI ofrece esta opción para usar distancias estandarizadas, la cual es muy recomendada. En el ejemplo anterior, el píxel estaría correctamente clasificado como caducifolio porque su distancia estandarizada a la media para caducifolias sería menor que 2 (quizás 1,95 en esta ilustración), mientras que para la arena sería mayor que 2 (probablemente cerca de 4 en esta ilustración).

Nuestra experiencia con MINDIST ha sido que éste funciona bastante bien cuando se usan distancias estandarizadas. Es más, a menudo tiene mejores resultados que un procedimiento de máxima verosimilitud cuando los sitios de entrenamiento tienen variabilidad alta.


## Paralelepípedos

El módulo PIPED implementa el procedimiento paralelepípedo para la clasificación de imágenes. El procedimiento paralelepípedo caracteriza cada clase por el rango de valores supuestos sobre cada banda. Este rango puede estar definido por los valores mínimos y máximos hallados en los datos del sitio de entrenamiento para esa clase, o (generalmente) por algún rango estandarizado de desviaciones de la media (Ej.:  $\pm 2$  desviaciones estándar). Con los datos de imágenes multiespectrales, estos rangos crean un polígono cercado en forma de caja con los valores previstos conocido como un *paralelepípedo*. A los píxeles no clasificados luego se les da una clase de cualquier caja paralelepípeda en la que encajen. Si un píxel no encaja en ninguna caja, se deja sin asignar. La Figura 17-4 ilustra este efecto.



**Figura 17-4**

Este clasificador tiene la ventaja de la velocidad y la habilidad para considerar la variabilidad cambiante de clases. Además, la forma rectangular da lugar al hecho de que la variabilidad sea diferente a lo largo de bandas diferentes. Sin embargo, el clasificador generalmente funciona de manera bastante pobre debido al potencial para la superposición de los paralelepípedos. Por ejemplo, los paralelepípedos coníferos y caducifolios se superponen en esta ilustración, dejando una zona de ambigüedad en el área superpuesta. Claramente, cualquier elección de una clase para los píxeles que se encuentren en la superposición es arbitraria.



**Figura 17-5**

Puede parecer que el problema de paralelepípedos superpuestos es improbable. No obstante, éstos son muy comunes debido al hecho de que los datos de la imagen a menudo están altamente correlacionados entre las bandas. Esto conduce a una distribución en forma de cigarro de los valores probables para una clase dada que está poco aproximada por un paralelepípedo como se muestra en la Figura 17-5.


Claramente, el procedimiento MINDIST no encontrará este problema, ya que la línea de separación entre estas clases se hallaría entre estas dos distribuciones. Sin embargo, en este contexto de correlación entre bandas (que está virtualmente garantizado), el procedimiento paralelepípedo produce ambas zonas de superposición y áreas poco representativas que en realidad no deberían ser incluidas en la clase. En general, entonces, el procedimiento paralelepípedo debería evitarse, a pesar de que es el clasificador supervisado más rápido.<sup>73</sup>

## Probabilidad Máxima

Para compensar las principales deficiencias de los procedimientos Paralelepípedo y Distancia Mínima a la Media, se emplea el procedimiento de Probabilidad Máxima, ofrecido por IDRISI a través del módulo MAXLIKE. El procedimiento de Máxima Verosimilitud está basado en la teoría de la probabilidad Bayesiana. Al usar la información de un grupo de sitios de entrenamiento, MAXLIKE emplea la media y los datos de varianza/covarianza de las firmas para estimar la probabilidad posterior de que un píxel pertenezca a cada clase.

En muchos sentidos, el procedimiento MAXLIKE es similar al MINDIST con la opción de la distancia estandarizada. La diferencia es que MAXLIKE representa la intercorrelación entre bandas. Al incorporar información acerca de la covarianza entre bandas así como también de su varianza inherente, MAXLIKE produce lo que puede ser conceptualizado como una zona elíptica de caracterización de la firma. En realidad, calcula la probabilidad posterior de pertenencia a cada clase, donde la probabilidad es más alta en la posición de la media de la clase, y disminuye en un patrón elíptico alejándose de la media, como se muestra en la Figura 17-6.

<sup>73</sup> En los primeros tiempos del procesamiento de imágenes cuando los recursos computacionales eran pobres, este clasificador se usaba comúnmente como un clasificador de *vista rápida* debido a su velocidad.



**Figura 17-6**

## **Análisis Discriminante Lineal (Clasificador Fisher)**

El último clasificador a ser discutido en esta sección es más difícil para describir gráficamente. El clasificador FISHER conduce un análisis discriminante lineal de los datos del sitio de entrenamiento para formar un grupo de funciones lineales que expresen el grado de apoyo por cada clase. La clase asignada a cada pixel es entonces esa clase que recibe el apoyo más alto luego de la evaluación de todas las funciones. Estas funciones tienen una forma similar a la de una ecuación de regresión lineal multivariada, donde las variables independientes son las bandas de la imagen, y la variable dependiente es la medida del apoyo. En realidad, las ecuaciones son calculadas de manera tal que maximizan la varianza entre clases y minimizan la varianza dentro de las clases. El número de ecuaciones es igual al número de bandas, cada una describe un hiperplano de apoyo. Las intersecciones de estos planos luego forman los bordes entre clases en el espacio de banda.

De los cuatro clasificadores supervisados rígidos, MAXLIKE y FISHER son los más poderosos. También son los más lentos para calcular. Sin embargo, con sitios de entrenamiento de alta calidad (es decir, homogéneos), ambos son capaces de producir excelentes resultados.

## **Clasificadores Blandos**

A diferencia de los clasificadores rígidos, los clasificadores blandos posponen la emisión de un juicio definitivo acerca de la pertenencia de clase de cualquier pixel a favor de un grupo de declaraciones sobre el grado de pertenencia de ese pixel en cada una de las clases posibles. Como los procedimientos tradicionales de clasificación supervisada, cada uno usa información de sitios de entrenamiento con el propósito de clasificar cada pixel de una imagen. No obstante, a diferencia de los clasificadores rígidos tradicionales, la producción no es un solo mapa de cobertura terrestre clasificado, sino un grupo de imágenes (una por clase) que expresan para cada pixel el grado de pertenencia a la clase en cuestión. En realidad, cada uno expresa el grado en el que cada pixel pertenece al grupo identificado por una firma de acuerdo a una de las siguientes métricas de pertenencia de grupo:

BAYCLASS	basada en la teoría de la probabilidad Bayesiana,
BELCLASS	basada en la teoría Dempster-Shafer,
MAHALCLASS	basada en la distancia Mahalanobis,
FUZCLASS	basada en la teoría de Grupo Difuso, y
UNMIX	basada en el modelo de Mezcla Lineal.

Es importante reconocer que cada una de estas métricas se encuentra en una categoría general de lo que se conoce como *Medidas Difusas* (Dubois y Prade, 1982) de las que el Grupo Difuso sólo es una instancia. La confusión (fuzziness) puede originarse por muchas razones y no solo porque un grupo mismo es difuso (o confuso). Por ejemplo, el error de medición puede conducir a la incertidumbre acerca de la pertenencia de clase de un pixel aún cuando las clases (grupos) están definidas de manera rígida. Es por esta razón que hemos adoptado el término *blando* (soft) – simplemente reconoce que la pertenencia de clase de un pixel frecuentemente es incierta por razones de origen variado.

## Archivos de Grupo de Imágenes

Debido a que la producción de cada uno de estos clasificadores blandos es un grupo de imágenes, cada uno además produce un archivo de grupo de imágenes raster (.rgf). Esto puede usarse con el cursor en modo consultas para examinar los valores de pertenencia de grupo para un pixel en cada clase simultáneamente en forma numérica o gráfica (vea la sección del Sistema de Ayuda on-line sobre Display (visualización)). Tenga en cuenta que la imagen de incertidumbre de clasificación descrita abajo también está incluida en cada archivo de grupo producido.

## Incertidumbre de Clasificación

Además de estas imágenes de pertenencia de grupo, cada uno de estos clasificadores blandos genera una imagen que expresa el grado de *incertidumbre de clasificación* que tiene acerca de la pertenencia de grupo de cualquier pixel. La incertidumbre de clasificación mide el grado en el cual ninguna clase sobresale con claridad por encima de las otras en la evaluación de pertenencia de clase de un pixel. En el caso de BAYCLASS, BELCLASS y FUZCLASS, ésta se calcula de la siguiente manera:

$$\text{Incertidumbre de clasificación} = 1 - \frac{\frac{\text{max} - \text{sum}}{n}}{1 - \frac{1}{n}}$$

donde

- max = el valor máximo de pertenencia de grupo para ese pixel
- sum = la suma de los valores de pertenencia de grupo para ese pixel
- n = el número de clases (firmas) consideradas

La lógica de esta medida es:

- El numerador de la segunda cifra expresa la diferencia entre el valor máximo de pertenencia de grupo y la dispersión total de los valores de pertenencia de grupo en todas las clases.
- El denominador de la segunda cifra expresa el caso extremo de la diferencia un valor máximo de pertenencia de grupo de 1 (y por lo tanto compromiso total con una sola clase) y la dispersión total de ese compromiso en todas las clases.
- Al sacar la tasa de estas dos cantidades, uno desarrolla una medida que expresa el grado de compromiso con una clase específica relativo al compromiso más grande posible que pueda hacerse. La incertidumbre de clasificación es entonces el complemento de esta proporción.

La medida de la incertidumbre desarrollada aquí es similar a la medida de entropía usada en la Teoría de la Información. Sin embargo, se diferencia en que se ocupa no sólo del grado de dispersión de los valores de pertenencia de grupo entre clases, sino también de la cantidad total de compromiso presente. A continuación hay algunos ejemplos que pueden clarificar este concepto.

### Ejemplos

Suponiendo un caso donde se están evaluando tres clases, considere aquellas con las siguientes asignaciones de pertenencia de grupo:

(0.0 0.0 0.0)	Incertidumbre de Clasificación = 1,00
(0.0 0.0 0.1)	Incertidumbre de Clasificación = 0,90
(0.1 0.1 0.1)	Incertidumbre de Clasificación = 1,00
(0.3 0.3 0.3)	Incertidumbre de Clasificación = 1,00
(0.6 0.3 0.0)	Incertidumbre de Clasificación = 0,55
(0.6 0.3 0.1)	Incertidumbre de Clasificación = 0,60
(0.9 0.1 0.0)	Incertidumbre de Clasificación = 0,15
(0.9 0.05 0.05)	Incertidumbre de Clasificación = 0,15
(1.0 0.0 0.0)	Incertidumbre de Clasificación = 0,00

Con UNMIX, en cambio, la incertidumbre de clasificación es medida como el error residual luego del cálculo de las fracciones de los miembros constitutivos. Esto se discutirá más adelante.

## BAYCLASS y la Teoría de la Probabilidad Bayesiana

BAYCLASS es una extensión directa del módulo MAXLIKE. Genera una imagen separada para expresar la probabilidad posterior de pertenencia a cada clase considerada según el Teorema de Bayes:

$$p(h|e) = \frac{p(e|h) \cdot p(h)}{\sum_i p(e|h_i) \cdot p(h_i)}$$

donde :

$p(h|e)$  = la probabilidad de que la hipótesis sea verdadera dada la evidencia (probabilidad posterior)

$p(e|h)$  = la probabilidad de encontrar esa evidencia dado que la hipótesis sea verdadera

$p(h)$  = la probabilidad de que la hipótesis sea verdadera sin importar la evidencia (probabilidad anterior)

En este contexto, la matriz de varianza/covarianza derivada de datos del sitio de entrenamiento es aquella que permite evaluar la probabilidad condicional multivariada  $p(e|h)$ . Esta cantidad luego es modificada por la probabilidad anterior de que la hipótesis sea verdadera, y luego normalizada por la suma de tales consideraciones en todas las clases. Este último paso es importante ya que supone que las clases consideradas son las únicas clases posibles como interpretaciones para el pixel en consideración. Entonces, hasta un apoyo débil para una interpretación específica puede parecer fuerte si es el más fuerte de las opciones posibles dadas.

Esta probabilidad posterior  $p(h|e)$  es la misma cantidad que evalúa MAXLIKE para determinar la clase más probable, y más aún, si las imágenes de salida de BAYCLASS fuesen enviadas directamente a HARDEN, el resultado sería igual al de MAXLIKE. En esencia, BAYCLASS es un clasificador *confidente*. Supone que la única interpretación posible de un pixel es una de esas clases para las cuales los datos del sitio de entrenamiento han sido establecidos. Por lo tanto no admite ignorancia. Como resultado, la falta de evidencia para una hipótesis alternativa constituye un apoyo para las hipótesis que quedan. En este contexto, un pixel para el cual los datos de reflectancia apoyan sólo superficialmente una clase particular es tratado como inequívocamente perteneciente a esa clase ( $p = 1,0$ ) si no existe apoyo para ninguna otra interpretación.

La motivación principal para el uso de BAYCLASS es la clasificación subpixel – es decir, para determinar hasta qué punto los pixeles mixtos existen en la imagen y sus proporciones relativas. También es de interés observar la base subyacente del procedimiento MAXLIKE. Sin embargo, para la *Evaluación de la Clasificación en Proceso* (IPCA), generalmente se prefiere el procedimiento BELCLASS debido a su reconocimiento explícito de que algún grado de ignorancia puede existir en el proceso de clasificación.

En el contexto del análisis mixto, las probabilidades de BAYCLASS son directamente interpretadas como declaraciones de representación proporcional. Entonces, si un pixel tiene probabilidades posteriores de pertenecer a caducifolias y coníferas de 0,68 y 0,32 respectivamente, esto sería interpretado como evidencia de que el pixel contiene un 68% de especie caducifolia y un 32% de conífera. Observe, sin embargo, que esto requiere varias suposiciones importantes para ser verdadero. Primero, necesita que las clases para las cuales los datos del sitio de entrenamiento han sido establecidos sean exhaustivas (es decir, no hay otras interpretaciones posibles para ese pixel). Segundo, supone que las distribuciones de probabilidad condicional  $p(e|h)$  no se superponen en el caso de los pixeles puros. En la práctica, estas condiciones pueden ser difíciles de cumplir.

Al hacer pruebas en Clark Labs, hemos encontrado que mientras BAYCLASS es efectivo para determinar los miembros constitutivos de los pixeles mixtos, a menudo no resulta tan efectivo para determinar las proporciones correctas. Por el contrario, hemos hallado que los procedimientos basados en el modelo de Mezcla Lineal (UNMIX) se desempeñan considerablemente mejor en este punto. No obstante, la Separación Espectral Lineal posee sus propias limitaciones espaciales. Consecuentemente, estamos a favor de un enfoque híbrido que usa las mejores cualidades de la descomposición Bayesiana y de la Separación Espectral Lineal, como se desarrollará más adelante.

## BELCLASS y la Teoría de Dempster-Shafer

BELCLASS es probablemente el más complejo del grupo de los clasificadores blandos en su teoría subyacente. Está basado en la teoría Dempster-Shafer – una variante de la teoría de la probabilidad Bayesiana que reconoce explícitamente la posibilidad de la ignorancia. La teoría Dempster-Shafer se explica más detalladamente en el capítulo **Apoyo en la Toma de Decisiones: Manejo de la Incertidumbre**. No obstante, una buena introducción puede ser proporcionados al considerar la producción de BAYCLASS.

Considera una clasificación donde los sitios de entrenamiento han sido desarrollados para las clases (conífera), (caducifolia), (césped), (urbana) y (agua). Si un pixel muestra algún grado de similitud con la clase (conífera) y con ninguna otra clase, BAYCLASS le asignará un valor de 1,0 a esa clase y de 0,0 a las demás. En realidad, hará esto

aún si el verdadero apoyo por la clase (coníferas) es bajo, porque la teoría de la probabilidad Bayesiana no reconoce el concepto de la ignorancia. Supone que la falta de evidencia *para* una hipótesis constituye evidencia *en contra* de esa hipótesis. Entonces, en este ejemplo, la ausencia de evidencia para cualquier combinación de (caducifolia césped urbana agua) es interpretada como evidencia de que debe ser (conífera), sin importar cuán débil sea en realidad la evidencia directa para (conífera) (siempre y cuando sea mayor que 0).

En contraste con esto, la teoría Dempster-Shafer no supone que posee información completa, pero acepta que el estado del conocimiento propio puede ser incompleto. La ausencia de evidencia acerca de una hipótesis es tratada simplemente como lo que es – falta de evidencia. A diferencia de la teoría de la probabilidad Bayesiana, no se supone que ésta, entonces, constituya evidencia en contra de esa hipótesis. Como consecuencia, puede haber una diferencia entre la creencia que uno tiene en una hipótesis y el descreimiento del asistente de uno en esa misma hipótesis.

En el lenguaje de la teoría Dempster-Shafer, el grado en el cual la evidencia provee apoyo concreto para una hipótesis se conoce como *creencia*, y el grado en el cual la evidencia no refuta esa hipótesis se conoce como *posibilidad*. La diferencia entre estos dos se conoce como *intervalo de creencia*, el cual actúa como una medida de la incertidumbre acerca de una hipótesis específica.

Volviendo al ejemplo anterior, si la evidencia apoya la clase (conífera) en un grado de 0,3 y todas las otras clases en un grado de 0,0; la probabilidad Bayesiana le asignará una probabilidad posterior de 1,0 a la clase (conífera). Sin embargo, la teoría Dempster-Shafer le asignaría una creencia de 0,3 a la clase (conífera) y una posibilidad de 1,0; produciendo un intervalo de creencia de 0,7. Más aún, le asignaría una creencia de 0,0 a todas las demás clases y una posibilidad de 0,7.

Si se considera una segunda evidencia, y se descubre que esta evidencia apoya la clase [urbana] en un grado de 0,6 y no apoya ninguna otra hipótesis, esto afectaría la hipótesis (conífera) al disminuir su posibilidad a un 0,4. En este punto, entonces, la creencia en (conífera) es de 0,3 y la posibilidad es de 0,4. Por lo tanto, nuestra incertidumbre acerca de esta clase es muy baja (0,1).

La combinación de evidencia es generalmente algo más compleja que lo que estos ejemplos artificiales sugieren y usa una lógica conocida como *Regla de Dempster*. El módulo Belief de IDRISI implementa esta regla. No obstante, BELCLASS está menos relacionado con la combinación de evidencia que con la descomposición de la misma para determinar el grado de apoyo (expresado como creencia o posibilidad) a cada una de las clases para las que se han suministrado datos del sitio de entrenamiento.<sup>74</sup>

Además de los conceptos de creencia y posibilidad, la lógica de la teoría Dempster-Shafer también puede expresar el grado en el cual el estado del conocimiento de uno no distingue las hipótesis. Esto se denomina *ignorancia*.

La ignorancia expresa la falta de integridad del conocimiento propio como una medida del grado en el cual no podemos distinguir ninguna de las hipótesis. Usando el ejemplo anterior, la ignorancia expresa el compromiso de uno con el grupo indistinguible de todas las clases (conífera caducifolia césped urbana agua) – la inhabilidad para distinguir a qué clase pertenece el pixel.

En su uso normal, la teoría Dempster-Shafer requiere que las hipótesis (clases) en consideración sean mutuamente exclusivas y exhaustivas. Sin embargo, al desarrollar BELCLASS, percibimos que las categorías no exhaustivas eran muy importantes también – que el pixel puede de verdad pertenecer a alguna clase desconocida, para la cual no

se ha proporcionado un sitio de entrenamiento. Para realizar esto necesitamos agregar una categoría adicional a cada análisis llamado (otro), y asignar cualquier falta de integridad en el conocimiento de uno al grupo indistinguible de todas las clases posibles (incluyendo esta adicional) – Ej.: (conífera caducifolia césped urbana agua otra). Esto genera un resultado consistente con la teoría Dempster-Shafer, pero que reconoce la posibilidad de que existan clases presentes acerca de las cuales no tenemos conocimiento alguno.

Definir la ignorancia como un compromiso con el grupo indistinguible de todas las clases sugiere que ésta puede tener alguna relación con la imagen de incertidumbre de clasificación producida por BAYCLASS. La imagen de incertidumbre de clasificación de BAYCLASS expresa la incertidumbre que tiene el clasificador al asignarle pertenencia de clase a un pixel. La incertidumbre es más alta siempre que no hay una clase que sobresalga con claridad del resto en la evaluación de pertenencia de clase para un pixel. Hemos hallado que en el contexto de BELCLASS, esta medida de la incertidumbre es casi idéntica a la de la ignorancia Dempster-Shafer. Como

<sup>74</sup> La lógica del proceso de descomposición está detallada en la descripción del módulo para BELCLASS en el Sistema de Ayuda on-line.



resultado, hemos modificado suavemente la producción de la imagen de incertidumbre de clasificación de BELCLASS para que genere una ignorancia Dempster-Shafer verdadera.<sup>75</sup>

El funcionamiento de BELCLASS es esencialmente idéntico al de BAYCLASS y también al de MAXLIKE. Se dan dos opciones de salida: creencias o posibilidades. En cualquiera de los casos, se produce una imagen separada de creencia o posibilidad para cada clase. Además, se produce una imagen de incertidumbre de clasificación que puede interpretarse en la misma manera que la imagen de incertidumbre de clasificación producida por todos los clasificadores blandos (pero que es verdaderamente una medida de la ignorancia Dempster-Shafer).

La principal motivación para usar BELCLASS es verificar la calidad de los datos propios del sitio de entrenamiento y la posible presencia de clases desconocidas durante la *Evaluación de Clasificación en Proceso*. En los casos donde uno cree que existen una o más clases desconocidas (y por consiguiente, que alguna porción de la ignorancia total se origina debido a la presencia de una clase desconocida), debe usarse la rutina de BELCLASS. BELCLASS realiza esto al agregar implícitamente (otra) clase al grupo de clases consideradas. Esta es una concesión teórica a la mecánica del proceso BELCLASS y no será directamente encontrada por el usuario.

Al comparar la producción de BELCLASS con la de BAYCLASS, Ud. notará una diferencia importante. Al observar las imágenes producidas por BAYCLASS, parecerá como si sus sitios de entrenamiento fuesen fuertes. BAYCLASS es un clasificador muy confiado (tal vez demasiado confiado) ya que no admite ignorancia alguna. BELCLASS, en cambio, parece ser un clasificador muy reservado. Aquí vemos un resultado en el que todas las incertidumbres en nuestra información se vuelven aparentes. No supone tener la información completa, pero reconoce explícitamente la posibilidad de que puedan existir una o más clases desconocidas.

## MIXCALC y MAXSET

En BELCLASS, la inquietud está dirigida al grado de pertenencia que exhibe cada pixel para cada una de las clases para las cuales se han proporcionado sitios de entrenamiento. No obstante, la lógica de la teoría Dempster-Shafer reconoce toda una jerarquía de clases, formada por las combinaciones indistinguibles de estas clases básicas. Por ejemplo, dadas las clases básicas (llamadas *simples*)<sup>76</sup> de (conífera)(caducifolia)(césped), la teoría Dempster-Shafer reconoce la existencia de todas las siguientes clases:

(conífera)  
(caducifolia)  
(césped)  
(conífera caducifolia)  
(conífera césped)  
(caducifolia césped)  
(conífera caducifolia césped)

La teoría Dempster-Shafer además permite hacer dos tipos diferentes de evaluación sobre cada una de estas clases. La primera obviamente es la creencia. La segunda es conocida como una *Asignación de Probabilidad Básica* (BPA). Ambas requieren una explicación adicional.

Cuando la evidencia brinda algún grado de compromiso con una de estas clases compuestas y no con alguno de sus integrantes por separado, esa expresión de compromiso se conoce como una Asignación de Probabilidad Básica (BPA). La BPA de una clase compuesta entonces representa el grado de apoyo a la presencia de uno o más de sus integrantes, pero sin la habilidad para distinguir cuál.

Dado este entendimiento de una BPA, la creencia en una clase compuesta se calcula por lo tanto como la suma de BPAs para esa clase y todas las subclases. Por ejemplo, para calcular la creencia en la clase (conífera caducifolia), debe agregar las BPAs para (conífera caducifolia), (conífera) y (caducifolia). La creencia es entonces un concepto más amplio que una BPA. Representa el compromiso total con todos los miembros de un grupo combinado.

En el contexto de los sensores remotos, estas clases compuestas son de interés ya que representan mezclas, y por ello, pueden usarse para un examen más detallado de la clasificación subpixel. Sin embargo, el número puro de tales clases resulta poco práctico para tener un módulo software que genere todas las clases posibles. Para un grupo de clases compuestas  $n$ , el número total de clases en la jerarquía entera es  $(2^n - 1)$ . Entonces, en un caso donde hay 16

<sup>75</sup> El nombre de archivo para la imagen de incertidumbre de clasificación en BELCLASS está compuesto de la siguiente manera: se concatena el prefijo suministrado por el usuario y la sílaba "clu".

<sup>76</sup> Claramente se observa que estos son grupos de clases. No obstante, debido a que la evidencia puede apoyar uno de estos grupos sin otra distinción acerca de qué miembros del grupo están apoyados, el grupo mismo puede entenderse como una clase.

clases de cobertura terrestre en consideración, se incluyen en la jerarquía total 65.535 clases – más de dos terabytes de producción para una escena completa del LANDSAT.

Al final resulta que, sin embargo, sólo un pequeño número de estas clases compuestas contienen alguna información significativa en una aplicación típica. Éstas pueden determinarse de manera efectiva ejecutando el módulo MAXSET.

Éste es un clasificador rígido que le asigna a cada pixel la clase con el mayor grado de compromiso de toda la jerarquía de clase Dempster-Shafer. El significado de estas mezclas puede determinarse mejor ejecutando el módulo AREA en el resultado de MAXSET. Entonces, MIXCALC puede usarse para calcular la mezcla BPA que se encuentra en el resultado de MAXSET.

## Creencia

Tanto BELCLASS como MIXCALC desarmen la evidencia para inferir la creencia y la posibilidad para cada clase. Uno de los motivos para realizar esto es que permite al usuario combinar información auxiliar con aquella determinada a partir de los datos de reflectancia. La nueva evidencia puede combinarse con el conocimiento existente usando el módulo Belief. Éste se describe en más profundidad en el capítulo **Apoyo en la Toma de Decisiones: Manejo de la Incertidumbre**, y se usa exactamente de la misma manera con los datos aquí descritos.

## FUZCLASS y la Teoría del Grupo Difuso

El tercer clasificador blando en IDRISI es FUZCLASS. Como lo indica el nombre, este clasificador está basado en la lógica subyacente de los Grupos Difusos. De la misma manera en que BAYCLASS y BELCLASS están basados en la lógica fundamental de MAXLIKE, FUZCLASS está basado en la lógica subyacente de MINDIST – es decir, la pertenencia a grupo difuso es determinada a partir de la distancia de los pixeles a las medias de las firmas como lo determina MAKESIG.

Hay dos parámetros importantes que deben establecerse cuando se usa FUZCLASS. El primero es la distancia de valor  $z$  donde la pertenencia difusa es cero. La lógica de esto es la siguiente.

Se supone que cualquier pixel en la misma ubicación en el espacio de banda que la media de la clase (como lo determina la aplicación de MAKESIG) tiene un grado de pertenencia de 1,0. Luego, mientras nos alejamos de esta posición, el grado de pertenencia a grupo difuso decrece progresivamente hasta que eventualmente alcanza cero en la distancia especificada. Esta distancia es especificada como un valor estándar (valor  $z$ ) para facilitar su interpretación. Por ello, al especificar una distancia de 1,96 forzaría el 5% de las celdas de los datos a tener una pertenencia difusa de 0, mientras que una de 2,58 forzaría un 1% a tener un valor de 0.

La segunda configuración de parámetro requerida es si los valores de pertenencia deben o no ser normalizados. La normalización supone (como BAYCLASS) que las clases son exhaustivas, y por lo tanto, que los valores de pertenencia para todas las clases de un solo pixel deben sumar 1,0. Esto se necesita estrictamente para generar grados verdaderos de pertenencia a grupo difuso. No obstante, en oposición a BELCLASS, la opción se provee para calcular los valores no normalizados. Como se sugirió antes, esto es particularmente importante en el contexto de la Evaluación de Clasificación en Proceso para evaluar una clasificación basada en MINDIST.

## UNMIX y el Modelo de Mezcla Lineal

El Modelo de Mezcla Lineal supone que la mezcla de materiales dentro de un pixel conduce a una firma agregada que es un promedio de área ponderada de las firmas de las clases constitutivas. Por ello, si dos materiales principales (llamados miembros finales en el lenguaje de la Separación Espectral Lineal) tuviesen firmas de 24, 132, 86 y 56, 144, 98 en tres bandas, una mezcla 50/50 de ambos debería producir una firma de 40, 138, 92. Usando este modelo simple, es posible estimar las proporciones de los integrantes que son miembros finales dentro de cada pixel al resolver un grupo de ecuaciones simultáneas. Por ejemplo, si encontrásemos un pixel con la firma 32, 135, 89, y supusiésemos que el pixel contiene una mezcla de los dos miembros finales mencionados, podríamos establecer el siguiente grupo de ecuaciones para resolver:

$$f1(24) + f2(56) = 32$$

$$f1(132) + f2(144) = 135$$

$$f1(86) + f2(98) = 89$$

donde  $f_1$  y  $f_2$  representan las fracciones (proporciones) de los dos miembros finales. Dicho sistema de ecuaciones simultáneas se puede resolver usando álgebra matricial para producir una estimación más acertada de  $f_1$  y  $f_2$  (0,75 y 0,25 en este ejemplo). Además, la suma de los residuales cuadrados entre los valores de firmas adecuados y los valores reales se puede usar como una medida de la incertidumbre en el ajuste.

La principal limitación de este enfoque es que el número de miembros finales no puede exceder el número de bandas. Esto puede constituir una limitación severa en el caso de las imágenes SPOT, aunque no implica consecuencias para las imágenes hiperespectrales. IDRISI ofrece tres estrategias (en UNMIX) para la Separación Espectral Lineal:

1. La estrategia para la separación espectral lineal estándar (como se indica abajo) para los casos donde hay suficientes bandas disponibles.
2. Una opción guiada por la probabilidad para los casos con bandas insuficientes. Aunque el número total de miembros finales posibles sea grande, el número que coexiste dentro de un solo pixel usualmente es pequeño (Ej.: 2-3). Esta estrategia usa un primer paso basado en el módulo BAYCLASS para determinar los integrantes más probables (hasta el número de bandas), con un segundo paso de separación espectral lineal para determinar sus fracciones. Los experimentos en Clark Labs han demostrado que esta estrategia produce excelentes resultados.
3. Una opción de búsqueda exhaustiva para aquellos casos donde existen bandas insuficientes. En esta instancia, uno especifica el número de integrantes a considerar (hasta el número total de bandas). Luego, prueba todas las combinaciones posibles de los miembros finales y registra las fracciones de esa combinación con la suma más baja de residuales cuadrados. Esta estrategia es considerablemente más lenta que las otras opciones. Además, los experimentos en Clark Labs han demostrado que esta estrategia produce resultados inferiores para el procedimiento guiado por probabilidades en los casos donde las firmas de los miembros finales se extraen de los sitios de entrenamiento. Deben usarse las firmas puras de miembros finales, creadas con ENDSIG.

Las firmas de miembros finales se especifican con archivos de firma estándar (.sig), creados con MAKESIG o bien con ENDSIG. MAKESIG se utiliza en los casos donde los miembros finales se derivan de los sitios de entrenamiento, mientras que ENDSIG se usa en los casos donde se conocen los valores puros de los miembros finales (como de una biblioteca espectral). Tenga en cuenta que solo se usa el valor medio en cada banda de estos archivos de firma— los datos de varianza/covarianza son ignorados.

## **Asignando Firmas Ambiguas (Difusas) en la Clasificación Supervisada**

Todas las discusiones sobre este punto suponen que los datos de firma fueron reunidos a partir de ejemplos puros de cada clase. Sin embargo, a veces esto resulta imposible. Por ejemplo, un lugar puro y uniforme de bosque de pino blanco puede ser difícil de encontrar porque las diferencias en el espaciado de los árboles permiten que distintos niveles del material de los estratos inferiores (quizás una mezcla de suelo, hojas de pino muertas y helechos) se vean a través del estrato superior. Desde la perspectiva de un solo pixel, entonces, existen diferentes grados de pertenencia en la clase de pino blanco que van desde 0,0 donde no hay ningún árbol de pino blanco dentro del pixel hasta 1,0 donde existe un estrato superior cerrado y denso de pino blanco (como una plantación). Por lo tanto, aunque el grupo de pinos blancos (clase) es en sí mismo inherentemente rígido, nuestra recolección de datos por pixeles que abarcan desde algunos a muchos metros hace que nuestra detección de ese grupo sea necesariamente de carácter difuso.

Wang (1990) ha citado ejemplos del problema anterior para postular que la lógica de los problemas en la toma de decisión sobre la pertenencia de clase en la percepción remota es la de los Grupos Difusos. No obstante, como se indicó anteriormente en este capítulo, a pesar de que este problema verdaderamente pertenece al campo de las Medidas Difusas, en la mayoría de los casos no es estrictamente un problema de Grupos Difusos. Por ejemplo, la clase de pino blanco mencionada antes no es un grupo difuso — no es ambiguo. Es sólo nuestra dificultad para detectar que éste está libre de otros tipos de cobertura lo que genera ambigüedad. Entonces, este es un problema de imprecisión que se puede manejar mejor con un procedimiento Bayesiano o Dempster-Shafer (que es en realidad el procedimiento usado por Wang, 1990).

Como se señaló antes, la ambigüedad puede originarse a partir de una variedad de fuentes, y no sólo debido a grupos difusos. Sin embargo, el caso especial de resolución y pixeles mixtos se encuentra comúnmente en el proceso de clasificación. Como resultado, es usual que hasta las mejores firmas tengan algún grado de mezcla de interclase. En dichos casos, se prefiere usar un procedimiento para el desarrollo de firmas que pueda reconocer esta ambigüedad. Wang (1990) propuso un interesante procedimiento para el desarrollo de firmas en este contexto que hemos

implementado en un módulo llamado FUZSIG. Como lo indica el nombre, el módulo es una variante de MAKESIG para el caso especial de datos ambiguos (es decir, difusos) del sitio de entrenamiento. No obstante, usamos la asociación con la ambigüedad en el sentido más general de medidas difusas. La lógica del procedimiento está construida sobre el concepto de las mezclas y debe limitarse a instancias donde éstas son la fuente de la ambigüedad o confusión creada.

El uso de FUZSIG requiere el seguimiento de una secuencia especial de operaciones.

## 1. Definir los Sitios de Entrenamiento

Este paso procede en la forma habitual: los sitios de entrenamiento son digitalizados usando la utilidad de digitalización en pantalla. Sin embargo, los sitios de entrenamiento no necesitan ser tan homogéneos – sólo se requiere que las proporciones relativas de los tipos de cobertura dentro de cada pixel de sitio de entrenamiento puedan ser estimadas.

## 2. Rasterizar los Sitios de Entrenamiento

Aunque este paso no sea estrictamente necesario, puede hacer que el próximo paso sea mucho más fácil si los sitios de entrenamiento son reunidos en una sola imagen raster. Esto se logra ejecutando el INITIAL para crear una imagen binaria byte en blanco (es decir, una iniciada con ceros), y luego rasterizando los polígonos digitalizados con RASTERVECTOR.

## 3. Crear una Matriz de División Difusa en el Taller de Bases de Datos

El próximo paso es crear una *matriz de división* difusa con los valores para indicar los grados de pertenencia de cada sitio de entrenamiento (o grupo de sitios de entrenamiento) en las clases candidatas. Esta se carga mejor trabajando las columnas de cada fila a la vez. Debido a que cada fila representa un sitio de entrenamiento (o grupo de sitios de entrenamiento), estime las proporciones de cada clase que ocurren dentro del sitio de entrenamiento e ingrese ese valor (como un número real de 0,0 a 1,0). En este contexto, los números deben sumar 1,0 a lo largo de cada fila, pero por lo general, no sumarán esa cantidad a lo largo de las columnas.

Una vez que la matriz de división difusa está completa, use el Export como opción de Values File del menú Database Workshop File para crear una serie de archivos de valores, uno por clase. A continuación, debe crear una serie de imágenes raster que expresen los grados de pertenencia para cada clase. Para hacer esto, en IDRISI emplee el ASSIGN para asignar cada archivo de valores a la imagen raster de sitio de entrenamiento creada en el paso previo (esta es la imagen de definición de característica para ASSIGN). Nombre la imagen de salida para cada clase usando un nombre que sea una concatenación de las letras “fz” más el nombre de la clase. Por ejemplo, si la clase se llama “conífera”, la imagen producida con la operación ASSIGN se va a llamar “fzconífera.” Este prefijo “fz” es un requerimiento para el siguiente paso.

## 4. Extraer las Firmas Difusas

El siguiente paso es crear las firmas difusas. Esto se logra con el módulo FUZSIG. El funcionamiento de FUZSIG es idéntico al de MAKESIG. Necesitará especificar el nombre del archivo que define sus firmas (si ha seguido los pasos anteriores, esto será el archivo de imagen que Ud. creó en el Paso 2), el número de bandas para usar en el desarrollo de las firmas, los nombres de las bandas y los nombres de las firmas que van a crearse. Es muy importante, sin embargo, que los nombres de las firmas coordinen con los nombres de las imágenes de grado de pertenencia difusa que Ud. creó en el Paso 3. Continuando con el ejemplo anterior, si especifica un nombre de firma como “conífera”, se debe haber una imagen llamada “fzconífera” en su directorio de trabajo. De manera similar, una firma llamada “urbana” estaría asociada con una imagen de grado de pertenencia difusa llamada “fzurbana”.

El producto de FUZSIG es un grupo de archivos de firmas (.sig) con formato idéntico al de las producciones de MAKESIG. FUZSIG le da a cada pixel un peso proporcional a su grado de pertenencia en la determinación de la media, varianza y covarianza de cada banda para cada clase (ver Wang, 1990). Entonces, un pixel que está predominantemente compuesto por coníferas tendrá un gran peso en la determinación de la firma de conífera, pero solo un peso bajo en la determinación de las firmas de otros integrantes.

Debido a que estos archivos de firmas son idénticos en formato a los generados por MAKESIG, éstos pueden ser usados con cualquiera de los clasificadores avalados por IDRISI, tanto rígidos como blandos. No obstante, hay algunos puntos importantes para tener en cuenta acerca de estos archivos:

- Las reflectancias mínima y máxima sobre cada banda no pueden ser evaluadas de manera significativa con el proceso de ponderación de FUZSIG. Como consecuencia, el valor mínimo y máximo registrado es derivado solamente de aquellos pixeles donde el grado de pertenencia para la firma en cuestión es mayor que 0,5. Esto usualmente produce un resultado idéntico a la producción de MAKESIG. Sin embargo, se recomienda que si se usa el clasificador PIPED con estas firmas, los paralelepípedos deben estar definidos por unidades de desviación

estándar en lugar de valores de datos mínimos y máximos.

- A diferencia de MAKESIG, FUZSIG no genera un grupo de archivos de píxeles de firmas (.spf) correspondiente a los archivos de firmas producidos. Como consecuencia, EDITSIG no puede usarse para examinar o modificar los archivos de firmas producidos. No obstante, como los archivos de firmas son simples archivos de texto ASCII, pueden ser examinados en Edit. Su estructura simple está explicada en el Sistema de Ayuda on-line.

## Endurecedores

Una vez que un clasificador blando ha sido aplicado a un grupo de imágenes multiespectrales, los resultados blandos pueden ser reevaluados para producir una clasificación rígida usando uno de los siguientes endurecedores del módulo HARDEN.

### BAYCLASS

Al usar los resultados de BAYCLASS, esta opción determina la clase que posee la probabilidad posterior máxima para cada celda, dado un grupo de imágenes de probabilidad. Se pueden producir hasta cuatro niveles de abstracción. El primero es la clase más probable recién descrita. El segundo produce la clase con la segunda probabilidad posterior más alta, y así sucesivamente, hasta el cuarto nivel de probabilidad más alta.

### BELCLASS

Al usar los resultados de BELCLASS, esta opción es esencialmente idéntica al endurecedor BAYCLASS, excepto que ésta está diseñada para usarse con las creencias Dempster-Shafer.

### FUZCLASS

Al usar los resultados de FUZCLASS, esta opción es esencialmente idéntica al endurecedor BAYCLASS, excepto que ésta está diseñada para usarse con Grupos Difusos.

### UNMIX

Al usar los resultados de UNMIX, esta opción es esencialmente idéntica al endurecedor BAYCLASS, excepto que ésta está diseñada para usarse con las fracciones mixtas producidas por UNMIX.

### MAHALCLASS

Al usar los resultados de MAHALCLASS, esta opción es esencialmente idéntica al endurecedor BAYCLASS, excepto que ésta está diseñada para usarse con las particularidades producidas por MAHALCLASS.

## Clasificación No Supervisada

### Lógica General

Las técnicas de clasificación no supervisada comparten una intención en común para descubrir las principales clases de cobertura terrestre que existen en la imagen sin conocimiento previo de los que pueden ser. Genéricamente, tales procedimientos se hallan en el campo del *análisis de agrupamientos* (cluster) porque éstos buscan grupos de píxeles con características de reflectancia similares en una imagen multi-banda. También son todas generalizaciones de ocurrencia de coberturas terrestres ya que se ocupan de descubrir las *principales* clases de cobertura terrestre, y por ello, tienden a ignorar aquellas con una frecuencia de ocurrencia muy baja. Sin embargo, dadas estas extensas universalidades, prácticamente no tienen nada más en común. Hay casi tantos enfoques de agrupamientos como sistemas de procesamiento de imágenes en el mercado. IDRISI no es la excepción. El procedimiento no supervisado principal que éste ofrece es único (CLUSTER).

No obstante, IDRISI además ofrece una variante de uno de los procedimientos más comunes (ISOCLUST). Como se ha implementado aquí, este procedimiento es verdaderamente una combinación iterativa de procedimientos no supervisados y supervisados, así como también lo es el tercer procedimiento ofrecido, el MAXSET.

## CLUSTER

El módulo CLUSTER de IDRISI implementa una variante especial de una técnica de análisis de grupos llamada Pico del Histograma (Richards, 1993). El procedimiento se puede entender mejor desde la perspectiva de una sola banda. Si uno tuviese una sola banda de datos, un histograma de los valores de reflectancia sobre esa banda mostraría un número de picos y valles. Los picos representan los grupos con valores más frecuentes asociados con los tipos de cobertura terrestre de ocurrencia común.

El procedimiento CLUSTER entonces investiga los picos buscando casos donde la frecuencia es mayor que la de sus vecinos inmediatos de cada lado. En el caso de dos bandas, estos picos serían colinas, mientras que para tres bandas serían esferas, y así sucesivamente. Entonces, el concepto puede extenderse hasta cualquier número de bandas. Una vez que los picos se han localizado, cada pixel en la imagen puede luego ser asignado a su pico más cercano, con cada una de dichas clases tituladas como un grupo. Es la tarea del analista identificar la clase de cobertura terrestre de cada grupo al mirar la imagen del grupo y compararla con las características del terreno.

CLUSTER ofrece dos niveles de generalización. Con el nivel amplio de generalización, los grupos deben ocurrir como picos distintos en el histograma multidimensional según se indicó anteriormente. No obstante, con el nivel fino de generalización, CLUSTER también reconoce los escalones en la curva como picos de grupos. Los escalones ocurren cuando dos agrupamientos adyacentes se superponen en gran medida. Los picos y los escalones son identificados en el histograma que se muestra en la Figura 17-7.




Figura 17-7

El procedimiento CLUSTER en IDRISI ha sido modificado y adaptado para poder trabajar con el caso especial de tres bandas descritas por una imagen compuesta a color de 8 bits creada con el módulo COMPOSITE. La razón de este cambio está basada en gran medida en el hecho de que el procedimiento involucrado en la creación de la imagen compuesta a color de 8 bits es esencialmente el mismo que el primer paso de la generación de histogramas multidimensionales en el algoritmo de grupos. Como es común experimentar con varios grupos de una sola imagen multibanda, la velocidad se mejora bastante porque este paso de generación de histogramas no se repite. Mientras puede parecer que la restricción para trabajar con un compuesto de tres bandas es limitante, tenga en cuenta que el “bandaje” subyacente de una imagen multispectral en el infrarrojo visible a medio rara vez es mayor que 2 o 3 (para confirmar esto, intente ejecutar el Análisis de Componentes Principales en un grupo de imágenes multibanda de resolución espectral más elevada). En la mayoría de los ambientes, la creación de imágenes compuestas usando las bandas rojas e infrarrojas cercanas, junto con una banda infrarroja media (como la Banda 5 del LANDSAT) capturará esencialmente toda la información en la imagen.


La experiencia en el uso de la rutina de CLUSTER ha demostrado que es rápida y capaz de producir excelentes resultados. Por otra parte, hemos aprendido que la siguiente secuencia de operaciones es particularmente útil.

1. Ejecute el CLUSTER usando las bandas más informativas disponibles (generalmente, estas incluyen la banda roja visible, la banda infrarroja cercana y la banda infrarroja media – Ej.: las bandas del LANDSAT TM 3, 4 y 5 respectivamente). Use el estiramiento lineal con la opción de saturación en un 1% de saturación las opciones “fine generalization level” (nivel fino de generalización) y “retain all clusters” (retener todos los grupos).

2. Despliegue un histograma de esta imagen. Este histograma muestra la frecuencia de pixeles asociados con cada uno de los grupos que pueden localizarse en la imagen. Muchos de estos grupos tienen frecuencias muy pequeñas, y por ello, son de alguna manera insignificantes. La Figura 17-8 presenta un ejemplo de dicho histograma.

Como se puede observar, hay tres grupos que dominan la imagen. Luego hay una ruptura profunda con un segundo conjunto de grupos fuertes hasta el Grupo 12. Luego hay un tercer conjunto que sigue hasta el Grupo 25, seguido por un pequeño conjunto de grupos muy insignificantes. La experiencia sugiere entonces que una buena generalización de los datos sería extraer los primeros 12 grupos, con un análisis más detallado puntualizando los primeros 25.

3. Una vez que el número de grupos para examinar ha sido determinado, vuelva a ejecutar el CLUSTER, pero esta vez elija una “fine generalization” (generalización fina) y establezca un “maximum number of clusters” (número máximo de grupos) hasta el número que Ud. determinó (Ej.: 12).



**Figura 17-8**

4. Despliegue la imagen resultante con una paleta de colores cualitativos y luego trate de identificar cada uno de los grupos por vez. Puede usar la opción interactiva de edición de leyenda (legend editing) para cambiar la leyenda y grabar su propia interpretación. También puede cambiar el color de esa categoría para que combine con un esquema lógico de colores. Además, recuerde que puede resaltar todos los píxeles pertenecientes a una categoría presionando el botón del mouse sobre un cuadro del color de categoría de la leyenda.

5. Al final del proceso de identificación, puede que necesite combinar varias categorías. Por ejemplo, el análisis de grupos pudo haber descubierto varias categorías de pavimento, como el asfalto y el concreto, que Ud. puede unir en una sola categoría. La manera más simple de realizar esto es usando el Edit para crear un archivo de valores que contenga las reasignaciones enteras. Este archivo tiene dos columnas. La columna izquierda registra el número original de grupos, mientras que la columna derecha debe contener el número de la nueva categoría a la cual debe ser reasignado. Luego de que este archivo ha sido creado, emplee el ASSIGN para asignar estos índices de categorías nuevas a los datos originales de grupo.

El procedimiento CLUSTER en IDRISI es rápido y muy eficiente para descubrir la estructura básica de la cobertura terrestre de la imagen. Además puede usarse como un paso preliminar para un proceso híbrido no supervisado/supervisado donde los grupos se usan como los sitios de entrenamiento para un segundo paso de clasificación usando el clasificador MAXLIKE.<sup>77</sup> Esto tiene la ventaja de permitir el uso de un número mayor de bandas de datos puros y también brinda un paso de clasificación más fuerte de píxeles para su grupo más similar. En realidad, esta lógica se halla en el procedimiento ISOCLUST descrito a continuación.

## ISOCLUST

El módulo ISOCLUST es un clasificador no supervisado auto-organizado iterativo basado en un concepto similar a la reconocida rutina ISODATA de Ball y Hall (1965) y a las rutinas de grupo como los procedimientos media-H y media-K. La lógica típica es la siguiente:

1. El usuario decide el número de grupos para descubrir. Uno se encuentra verdaderamente ciego al tomar esta decisión. Como consecuencia, una estrategia común es pedir un número grande y luego agregar grupos después de la interpretación. Una estrategia más eficiente para este problema se ofrece más abajo, y está basada en la implementación específica en el IDRISI.

<sup>77</sup> Esto es posible debido a que MAKESIG puede crear firmas basadas en sitios de entrenamiento definidos por un archivo vectorial o por una imagen. En cualquiera de los casos, se usa la opción de la imagen.

2. Un conjunto de grupos N luego es colocado arbitrariamente en el espacio de banda. En algunos sistemas, estas ubicaciones son asignadas al azar. Aunque en la mayoría, son colocadas sistemáticamente dentro de la región de reflectancias de frecuencia alta.
3. Luego los pixeles son asignados a su ubicación de grupo más cercano.
4. Después de que todos los pixeles han sido asignados, se computa una nueva ubicación media.
5. Los Pasos 3 y 4 se repiten iterativamente hasta que no se produzca ningún cambio significativo en la producción.

La implementación de esta lógica general en IDRISI es diferente en varios aspectos.

- Luego de ingresar las bandas de imágenes crudas para utilizar, se le presentará un histograma de grupos que expresa la frecuencia con la cual éstos ocurren en la imagen. Debe examinar este gráfico y buscar rupturas significativas en la curva.

Éstas representan cambios importantes en la generalidad de los grupos. Especifique el número de grupos a crearse sobre una de estas rupturas principales.

- El proceso de generación de grupos en realidad se hace con el módulo CLUSTER del IDRISI. CLUSTER es verdaderamente un algoritmo de agrupamiento (en oposición a una operación de segmentación como la que se utiliza en muchas rutinas de agrupamiento así llamadas). Esto conduce a una colocación de grupos mucho más eficiente y exacta que la colocación sistemática o aleatoria.

- El proceso iterativo utiliza un procedimiento de Máxima Verosimilitud completo. En realidad, Ud. notará que éste utiliza reiteradas veces los módulos MAKESIG y MAXLIKE. Esto provee un procedimiento de asignación de grupos muy fuerte.

El procedimiento ISOCLUST es relativamente nuevo para el IDRISI. Por lo tanto, lo invitamos a hacer comentarios y sugerencias basadas en experiencias que Ud. haya tenido con este módulo.

## MAXSET

Como se describió anteriormente, MAXSET es un clasificador rígido que le asigna a cada pixel la clase con el mayor grado de compromiso de toda la jerarquía de clase Dempster-Shafer que describe todas las clases y sus combinaciones jerárquicas. Aunque se ejecuta como si fuese un clasificador supervisado (requiere datos del sitio de entrenamiento), finalmente se comporta como un clasificador no supervisado porque puede asignar un pixel a una clase para la que no se han suministrado datos exclusivos de entrenamiento.

MAXSET es muy similar en concepto a los clasificadores PIPED, MINDIST y MAXLIKE ya que realiza una determinación rígida de la clase más probable a la que pertenece cada pixel según su propia lógica interna de operación. MAXSET es diferente, sin embargo, ya que reconoce que la mejor asignación de un pixel puede ser a una clase mixta en lugar de simple. Por ejemplo, puede determinar que un pixel más probable pertenece a una clase mixta de bosque de coníferas y caducifolio que a una clase de coníferas o caducifolio exclusivamente. La lógica usada al hacer esto está derivada de la teoría Dempster-Shafer, una variante especial de la teoría de la probabilidad Bayesiana que se describe en profundidad en la sección sobre el clasificador blando BELCLASS más arriba. La teoría Dempster-Shafer brinda una lógica para expresar la creencia de uno en el grado en el que un ítem pertenece a un grupo particular. MAXSET evalúa el grado de apoyo a la pertenencia de cada pixel en la jerarquía de grupos que incluye cada una de las clases básicas más todas las combinaciones posibles de clases. Entonces, por ejemplo, en un caso con las clases de cobertura terrestre básicas A, B y C, el MAXSET evalúa el grado de pertenencia en cada una de las siguientes clases:

[A]  
[B]  
[C]  
[A,B]  
[A,C]  
[B,C]  
[A,B,C]



La importancia de los supergrupos (grupos con combinaciones de clases) es que representan combinaciones indistinguibles de las clases básicas. Entonces, cuando la evidencia apoya la combinación [A,B], se puede interpretar como apoyo a A o B, o a A y B, pero es incapaz de determinar a cuál. Las razones para esto son básicamente dos. La evidencia es incompleta, o bien el grupo indistinguible realmente existe. Por ello, si MAXSET concluye que un pixel pertenece al grupo indistinguible (conífera, caducifolia), puede deberse a que el pixel verdaderamente pertenece a una clase mixta de bosques, o bien puede significar simplemente que los sitios de entrenamiento elegidos para estas dos clases han producido firmas ambiguas.

MAXSET es un punto excelente para comenzar la Evaluación de Clasificación en Proceso (como se describe a continuación).

## Percepción Remota Hiperespectral

Como se indicó en la introducción a este capítulo, IDRISI incluye un grupo de rutinas para trabajar con datos hiperespectrales. Los procedimientos básicos son similares a los usados con la clasificación supervisada de datos multiespectrales. Las firmas se desarrollan para cada cobertura terrestre de interés, luego se clasifica la imagen entera usando la información de esas firmas. Los detalles del proceso se brindan a continuación.

### Importando Datos Hiperespectrales

IDRISI trabaja con datos hiperespectrales como una serie – es decir, como una colección de imágenes independientes que están asociadas a través de un archivo de grupo de imágenes raster (.rgf) o un archivo de banda de sensor (.sbf).

Muchas imágenes hiperespectrales disponibles hoy son distribuidas en formato Banda intercalada por Línea (BIL). Por ello, tal vez necesite usar el GENERICRASTER en el grupo de módulos de importación/exportación para convertir estos datos al formato IDRISI. Además, si los datos provienen de un sistema UNIX en formato de 16 bits, asegúrese de indicar esto dentro del cuadro de diálogo del GENERICRASTER.

### Desarrollo de Firmas Hiperespectrales

El paso del desarrollo de firmas usa el módulo HYPERSIG, el cual crea y visualiza archivos de firmas hiperespectrales. Pueden emplearse dos fuentes de información con HYPERSIG para desarrollar firmas hiperespectrales: sitios de entrenamiento (como se describió antes en la sección de clasificación supervisada) o archivos de curvas espectrales de biblioteca.

### Desarrollo de Firmas Basado en Imágenes

IDRISI ofrece un procedimiento supervisado y uno no supervisado para el desarrollo de firmas basado en imágenes. La primera estrategia implica usar un procedimiento similar al explicado en secciones anteriores para la clasificación supervisada donde los sitios de entrenamiento son delineados en la imagen y las firmas son desarrolladas a partir de sus características estadísticas. Debido al gran número de bandas involucradas, los pasos de desarrollo y clasificación de firmas emplean procedimientos diferentes a los utilizados con los datos multiespectrales. Además, existe una pequeña variación en la delineación de los sitios de entrenamiento que debe ser introducida. Los pasos son:

1. Crear un compuesto de colores usando tres de las bandas hiperespectrales y digitalizar los sitios de entrenamiento.
2. Rasterizar el archivo vectorial de los sitios de entrenamiento usando INITIAL para crear una imagen en blanco y luego RASTERVECTOR para rasterizar los datos.
3. Ejecutar HYPERSIG para crear un archivo de firmas hiperespectrales<sup>78</sup> para cada clase de cobertura terrestre. Los archivos de firmas hiperespectrales tienen una extensión .hsg, y son similares en su intención (aunque diferentes en estructura) a un archivo de firmas multiespectrales (.sig).
4. Ejecute cualquiera de los módulos HYPERSAM, HYPERMIN, HYPERUSP, HYPEROSP, HYPERUNMIX o HYPERABSORB para clasificar la imagen.

---

<sup>78</sup> Los contenidos de este archivo también se conocen como *espectros de la imagen*.

El procedimiento no supervisado es de cierta forma experimental. HIPERAUTOSIG descubre firmas basándose en el concepto de potencia de la firma. Aquellos usuarios que deseen experimentar con esto deben consultar el Sistema de Ayuda on-line para obtener detalles específicos.

## Desarrollo de Firmas Basado en Bibliotecas

La segunda estrategia para la clasificación de datos hiperespectrales se basa en el uso de una biblioteca de curvas espectrales asociadas con materiales específicos de la superficie terrestre. Estas curvas espectrales<sup>79</sup> son medidas con una precisión muy elevada en un laboratorio. Usualmente contienen más de mil lecturas espaciadas tan finamente como por 0,01 micrómetro sobre los rangos visible, infrarrojo cercano y medio. Claramente, aquí hay una gran cantidad de datos. Sin embargo, hay un número de temas importantes para considerar al usar estas curvas de biblioteca.

Como las curvas son desarrolladas en un laboratorio, las medidas son tomadas sin una atmósfera interviniente. Como consecuencia, existen medidas para las áreas del espectro donde la percepción remota tiene dificultad para obtener imágenes utilizables. Por ello, Ud. tal vez necesite eliminar esas bandas en las que la atenuación atmosférica es fuerte. Una forma simple de medir qué bandas tienen una atenuación atmosférica significativa es ejecutar el PROFILE y examinar la desviación estándar de las características seleccionadas sobre el grupo de imágenes hiperespectrales. La absorción atmosférica tiende a causar un aumento dramático en la variabilidad de firmas de características. Para eliminar estas bandas, edite el archivo de bandas del sensor, descrito a continuación, para borrar sus entradas y ajustar el número de bandas en la parte superior de archivo de manera concordante.

Aún en las bandas sin una atenuación severa, los efectos atmosféricos pueden causar discrepancias importantes entre las curvas espectrales medidas en el laboratorio y aquellas determinadas a partir de las imágenes hiperespectrales. Como consecuencia, IDRISI supone que si Ud. está trabajando con bibliotecas espectrales, las imágenes ya han sido corregidas atmosféricamente. El módulo SCREEN se puede usar para detectar las bandas en las que la dispersión atmosférica ha causado una degradación considerable en la imagen. El módulo ATMOSC se puede usar luego sobre las bandas restantes para corregir la absorción atmosférica y la niebla.

Las curvas espectrales de bibliotecas están disponibles en un número de sitios de investigación en la red, como el United States Geological Survey (USGS) Spectroscopy Lab (<http://speclab.cr.usgs.gov>). Estos archivos de curvas necesitan ser editados para cumplir con las especificaciones del IDRISI. El formato usado en IDRISI es virtualmente idéntico al empleado por el USGS. Éste es un archivo de texto ASCII con una extensión .isc. Los detalles de la estructura del archivo se pueden hallar en la sección sobre formatos de archivos del Sistema de Ayuda on-line. Los archivos de curvas espectrales son almacenados en un subdirectorio del directorio de programa de IDRISI llamado “waves” (ondas) (Ej.: c:\idrisiSelva\waves) y además se ha incluido una muestra de archivos de biblioteca.

Los archivos de curvas espectrales no se aplican a ningún sistema de sensores específico. En cambio, están diseñados como una referencia general de la que se puede derivar la reflectancia esperada para cualquier sistema de sensores para crear un archivo de firmas hiperespectrales. Esto se logra usando el módulo HYPERSIG.

Para que HYPERSIG cree una firma hiperespectral a partir de un archivo de curvas espectrales de biblioteca, deberá acceder a un archivo que describe el sistema de sensores en uso. Este es un *archivo de bandas del sensor* con una extensión .sbf que también se encuentra en el subdirectorio “waves” del directorio de programa de IDRISI. El archivo debe estar en formato ASCII y los detalles de la estructura del archivo se pueden hallar en la sección sobre formatos de archivos del Sistema de Ayuda on-line.

Con fines comparativos, se ha agregado como muestra un archivo para el sistema AVIRIS, junio de 1992, (aviris92.sbf) en el subdirectorio “waves” del directorio de programa de IDRISI (Ej.: c:\idrisiSelva\waves\aviris92.sbf).

Una vez que las firmas hiperespectrales han sido creadas para cada una de las clases de cobertura terrestre, se puede proceder con la clasificación de las imágenes con los módulos HYPERSAM o HYPERMIN.

## PROFILE

El módulo PROFILE brinda una herramienta adicional para explorar los datos hiperespectrales. Un perfil generado sobre una serie hiperespectral mostrará gráficamente (o numéricamente) cómo la reflectancia en una ubicación cambia de una banda a la próxima a través de toda la serie. Entonces, el resultado es un patrón de respuesta espectral para las ubicaciones particulares identificadas.

---

<sup>79</sup> Los contenidos de este archivo también se conocen como *espectros de la biblioteca*.

PROFILE requiere una imagen raster de los lugares de muestra que van a ser perfilados. Se pueden generar hasta 15 perfiles simultáneamente,<sup>80</sup> correspondientes a los sitios de muestra con valores de índice de 1-15. Un sitio de muestra puede consistir en uno o muchos píxeles ubicados en grupos contiguos o bien en varios grupos desconectados.

La segunda pieza de información que requiere el PROFILE es el nombre de un archivo que contiene los nombres de los archivos de imágenes de IDRISI que forman la serie hiperespectral. Aquí hay dos opciones. Puede usar tanto un archivo de grupo de imágenes (.rgf) como un archivo de bandas de sensor (.sbf) porque ambos contienen esta información. En cualquiera de los casos, deberá haber creado uno de estos antes de ejecutar el PROFILE. Tal vez le convenga elegir la opción del archivo de bandas de sensor ya que éste se puede usar con otras operaciones también (como HYPERSIG).

## Clasificación de Imágenes Hiperespectrales

IDRISI ofrece un rango de procedimientos para la clasificación de imágenes hiperespectrales. Todos, excepto uno (HYPERABSORB), funcionan mejor con firmas desarrolladas a partir de los sitios de entrenamiento, y pueden dividirse en clasificadores rígidos y blandos.

### Clasificadores Hiperespectrales Rígidos

#### HYPERSAM

HYPERSAM es una implementación del algoritmo Mapeo del Ángulo Espectral para la clasificación de imágenes hiperespectrales (Kruse y otros, 1993). El algoritmo Mapeo del Ángulo Espectral es un procedimiento de ángulo mínimo diseñado específicamente para usar con datos de biblioteca de curvas espectrales (aunque también se puede usar con firmas basadas en imágenes).

La información de reflectancia grabada en un archivo de curvas espectrales (.isc) se mide en un laboratorio bajo condiciones constantes de observación. Sin embargo, los datos en una imagen hiperespectral contienen variaciones adicionales que existen debido a variaciones en la iluminación. Por ejemplo, la elevación solar varía con la época del año y las variaciones topográficas conducen a variaciones de aspecto relativas al sol. Como consecuencia, pueden existir diferencias significativas entre los patrones de respuesta espectral grabados por el sistema del sensor y aquellos medidos en el laboratorio. El algoritmo Mapeo del Ángulo Espectral está basado en la suposición de que las variaciones en las condiciones de iluminación conllevan a un grupo de firmas que se encuentran a lo largo de una línea conectada al origen del espacio de banda como se ilustra en la Figura 17-9.





Figura 17-9

Entonces, en la presencia de variaciones importantes en la iluminación, se anticipa que un clasificador tradicional basado en la distancia tiene cierta dificultad para identificar la característica en todos los casos. El Mapeo de Ángulo Espectral emplea entonces un enfoque de ángulo mínimo. Esencialmente, trata cada firma como un vector. Luego, al comparar el ángulo formado por un píxel desconocido, el origen y una media de clase, y al comparar eso con todas las otras clases, la clase que será asignada al píxel desconocido es aquella con el ángulo mínimo, como se ilustra en la Figura 17-10.

<sup>80</sup> La visualización puede resultar bastante difícil de leer cuando se generan más de unos pocos perfiles al mismo tiempo. En condiciones normales, tal vez deba limitar los perfiles a no más de 5 sitios.



**Figura 17-10**

En la figura anterior, el pixel desconocido es asignado a la Clase 1 porque el ángulo que forma con el pixel desconocido (a) es más pequeño que el de la Clase 2 ®

## **HYPERMIN**

HYPERMIN es un clasificador de distancia mínima para datos hiperespectrales específicamente diseñado para usar con firmas basadas en imágenes desarrolladas a partir de sitios de entrenamiento. Utiliza una lógica idéntica a la del clasificador rígido multiespectral MINDIST que usa distancias estandarizadas.

## **Clasificadores Hiperespectrales Blandos**

### **HYPERUNMIX**

HYPERUNMIX utiliza el mismo enfoque que la opción Separación Espectral Lineal del UNMIX, exceptuando que éste emplea archivos de firmas hiperespectrales.

### **HIPEROSP**

HYPERUNMIX usa un procedimiento conocido como la Proyección del Subespacio Ortogonal. Está muy relacionado con HYPERUNMIX ya que se basa en la lógica de la Separación Espectral Lineal. Sin embargo, intenta mejorar la tasa de señal-ruido para un tipo de cobertura específico eliminando explícitamente los efectos contaminantes de los elementos mixtos. El resultado es una imagen que expresa el grado de apoyo a la presencia de la firma en cuestión. Observe que esta medida no es una fracción en sí, sino simplemente una medida de apoyo.

### **HYPERUSP**

HYPERUSP es un clasificador blando no supervisado basado en la lógica de HYPERAUTOSIG para el desarrollo de firmas (grupos), y en la de HYPERUNMIX para la clasificación blanda.

## **Clasificadores Hiperespectrales para Usar con Espectros de Biblioteca**

IDRISI ofrece un solo clasificador específicamente diseñado para usar con espectros de biblioteca (HYPERABSORB). Su funcionamiento básico es similar al del algoritmo TRICORDER (ahora renombrado TETRACORDER) desarrollado por el USGS.

### **HYPERABSORB**

HYPERABSORB busca específicamente la presencia de características de absorción asociadas con materiales específicos. Sigue una lógica que ha demostrado ser particularmente útil en el mapeo de minerales en ambientes áridos y extraterrestres. El principio básico es el siguiente. Ciertos materiales causan patrones de absorción distintivos en los espectros de biblioteca. Los ejemplos familiares incluyen la absorción masiva en las longitudes de onda roja y azul debido a la presencia de clorofila, y las características distintivas de absorción del agua en la infrarroja media. No obstante, muchos minerales exhiben características de absorción muy específicas y reducidas relacionadas con el movimiento de los electrones en rejillas de cristal y con los efectos de vibración de las moléculas. HYPERABSORB mide el grado de absorción evidente en los píxeles comparado con un espectro de biblioteca por medio de un proceso de eliminación continua y análisis de profundidad. El Sistema de Ayuda on-line brinda detalles

específicos del proceso. Sin embargo, el concepto básico es co -registrar el espectro del pixel y el espectro de biblioteca calculando el casco convexo de cada uno.

Esto es una polilínea dibujada por encima de la parte superior de la curva para que ningún punto en el espectro original se encuentre encima de la polilínea, y en la que no ocurren secciones cóncavas (valles) dentro de la polilínea. Al usar segmentos de esta polilínea como un dato, se mide la profundidad de la absorción para los puntos intermedios. La correlación entre las profundidades de la absorción en el espectro del pixel y el espectro de biblioteca produce una medida de adecuación, mientras que el volumen del área de absorción relativo al del espectro de biblioteca produce una medida de abundancia.

El análisis de imágenes hiperespectrales aún se encuentra en gran medida en una etapa de desarrollo. Le damos la bienvenida a sus comentarios acerca de las experiencias en el uso de cualquiera de estos procedimientos y a sus sugerencias para mejorarlos.

## Referencias y Lecturas Complementarias

Ball, G.H., y Hall, D.J., 1965. *A Novel Method of Data Analysis and Pattern Classification*, Stanford Research Institute, Menlo Park, California.

Clark, R.N., A.J. Gallagher, y G.A. Swayze, 1990, Material absorption band depth mapping of imaging spectrometer data using a complete band shape least-squares fit with library reference spectra, *Proceedings of the Second Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop*. JPL Publication 90-54, 176-186.

Clark, R.N., G.A. Swayze, A. Gallagher, N. Gorelick, y F. Kruse, 1991, Mapping with imaging spectrometer data using the complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials, *Proceedings of the Third Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop*, JPL Publication 91-28, 2-3.

Eastman, J.R., Kyem, P.A.K., Toledano, J., and Jin, W., 1993. *GIS and Decision Making*, UNITAR, Génova.

Kruse, F.A., Lefkoff, A.B., Boardman, J.W., Heidebrecht, K.B., Shapiro, A.T., Barloon, P.J., and Goetz, A.F.H., 1993. The Spectral Image Processing System (SIPS)—Interactive Visualization and Analysis of Imaging Spectrometer Data, *Remote Sensing of the Environment*, 44: 145-163.

Harsanyi, J. C. y Chang, C.-I., 1994. Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach. *IEEE Transactions on Geoscience and Remote Sensing*, 32(4), pp.779-785.

Richards, J.A., 1993. *Remote Sensing Digital Image Analysis: An Introduction*, Second Edition, Springer-Verlag, Berlin. Settle J.J. and N.A. Drake, 1993, Linear mixing and the estimation of ground proportions, *International Journal of Remote Sensing*, 14(6), pp. 1159-1177.

Shimabukuro Y.E. y J.A. Smith, 1991, The least-squares mixing models to generate fraction images derived from remote sensing multispectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 29(1), pp.16-20.

Sohn, Y. y R.M. McCoy, 1997, Mapping desert shrub rangeland using spectra unmixing and modeling spectral mixtures with TM data, *Photogrammetric Engineering and Remote Sensing*, 63(6) pp.707-716.

Wang, F., 1990. Fuzzy Supervised Classification of Remote Sensing Images, *IEEE Transactions on Geoscience and Remote Sensing*, 28(2): 194-201.

# CAPÍTULO 18 - Índices de Vegetación

por Amadou Thiam y J. Ronald Eastman

## Introducción

El análisis de la vegetación y la detección de los cambios en los patrones de vegetación son claves para la evaluación y el monitoreo de recursos naturales. Entonces no resulta sorprendente que la detección y la evaluación cuantitativa de la vegetación verde es una de las aplicaciones principales de la percepción remota para el manejo de recursos ambientales y la toma de decisiones.

Las capas saludables de la vegetación verde interactúan bastante distintivamente con la energía en las regiones visible e infrarroja cercana del espectro electromagnético. En las regiones visibles, los pigmentos de las plantas (más notablemente la clorofila) causan una fuerte absorción de energía, principalmente para la realización de la fotosíntesis. Los picos de absorción están en las áreas roja y azul del espectro visible, por lo tanto producen la característica apariencia verde de la mayoría de las hojas. En la infrarroja cercana, en cambio, ocurre una interacción muy diferente. En esta región, la energía no es utilizada para la fotosíntesis, sino que es en gran medida dispersada por la estructura interna de la mayoría de las hojas, conduciendo a una reflectancia aparentemente muy alta en la zona infrarroja cercana. Es este fuerte contraste entonces, más particularmente entre la cantidad de energía reflejada en las regiones roja e infrarroja cercana del espectro electromagnético, el tema que ha ocupado el foco de atención de una gran variedad de intentos para desarrollar índices cuantitativos de la condición de la vegetación usando imágenes de sensores remotos.

El propósito de este capítulo es representar un grupo de modelos de índices de vegetación (VIs) diseñados para proveer una evaluación cuantitativa de la biomasa de vegetación verde. Los índices propuestos son aplicables en imágenes satelitales de resolución espacial alta y baja, como NOAA AVHRR, LANDSAT TM y MSS, SPOT HRV/XS, y en cualquier otra similar a éstas que perciba en las regiones roja e infrarroja cercana. Estas imágenes han sido usadas en una variedad de contextos para evaluar la biomasa verde y también se han utilizado como representación del cambio ambiental general, especialmente en el contexto de la sequía (Kogan, 1990; Tripathy y colaboradores, 1996; Liu y Kogan, 1996) y en la evaluación del riesgo de degradación del terreno. Como consecuencia, se ha prestado un interés especial en la evaluación de la biomasa verde en ambientes áridos donde el fondo del suelo se torna un componente significativo de la señal detectada.

Este capítulo revisa el carácter de más de 20 índices brindados por los módulos TASSCAP y VEGINDEX en el sistema software de IDRISI, que se ofrecen para facilitar el uso de estos procedimientos y para continuar el debate relacionado con este índice ambiental muy importante. Recibimos sus comentarios sobre los índices actualmente incluidos en IDRISI y también sus sugerencias para futuras incorporaciones al grupo.

## Clasificación de los Índices de Vegetación

Jackson y Huete (1991) clasifican los índices en dos grupos: índices *basados en la pendiente* (slope) y *basados en la distancia*.

Para apreciar esta distinción, es necesario considerar la posición de los píxeles de vegetación en un gráfico bidimensional (*o esquema biespectral*) de reflectancia roja versus infrarroja. Los índices basados en la pendiente son combinaciones aritméticas simples que se concentran en el contraste entre los patrones de respuesta espectral de la vegetación en las porciones roja e infrarroja cercana del espectro electromagnético. Se denominan así porque cualquier valor particular del índice se puede producir por medio de un grupo de valores de reflectancia roja/infrarroja cercana que forman una línea que surge del origen de un esquema biespectral. Entonces, se pueden distinguir niveles diferentes del índice al producir un espectro de dichas líneas que difieren en su pendiente. La Figura 19-1a, por ejemplo, muestra un espectro de líneas del Índice de Vegetación de la Diferencia Normalizada (NDVI, el más comúnmente usado de este grupo) que oscilan desde -0,75 en dirección de las agujas del reloj hasta +0,75 (tomando la porción infrarroja como el eje X y la roja como el eje Y) con los valores del NDVI de 0 formando la línea diagonal.




Figura 19-1

En contraste con el grupo basado en la pendiente, el grupo basado en la distancia mide el grado de vegetación presente al determinar la diferencia entre la reflectancia de cualquier pixel y la reflectancia del suelo desnudo. Un concepto clave aquí es que un esquema de las posiciones de los pixeles del suelo desnudo de niveles de humedad variables en un esquema biespectral tiende a formar una línea (conocida como *línea del suelo* (soil line)). Mientras la cobertura de la capa de vegetación aumenta, este suelo de fondo se volverá cada vez más oscuro, y los pixeles de vegetación muestran una tendencia a una distancia perpendicular en aumento hacia esta línea del suelo (Figura 19-1b). Todos los miembros de este grupo (como el Índice de Vegetación Perpendicular – PVI) requieren que la pendiente y la ordenada al origen (intercept) de la línea del suelo estén definidas para la imagen correspondiente al análisis.

A estos dos grupos de índices de vegetación, se puede agregar un tercer grupo llamado índices de *transformación ortogonal*. Los índices ortogonales llevan a cabo una transformación de las bandas espectrales disponibles para formar un nuevo grupo de bandas no correlacionadas dentro de las cuales se puede definir una banda del índice de vegetación verde. La transformación Tasseled Cap es tal vez la más reconocida de este grupo.

**Una Nota Especial acerca de las Escalas de Medición:** IDRISI se diferencia de la mayoría de los otros SIG y demás software de procesamiento de imágenes porque éste acepta imágenes de números reales. Entonces las siguientes descripciones detallan estos índices de vegetación sin un re-escalado para adecuarse a tipos de datos más limitados. Sin embargo, en la mayoría de las implementaciones, se necesita un re-escalado subsiguiente para hacer el índice apto para la expresión en una forma entera (Ej.: un re-escalado de valores de un rango de números reales de -1,0 a +1,0 en un rango de números enteros de 0 a 255). En IDRISI, esto no se necesita, y por ello los índices son producidos y descritos en su forma más pura.

## Los Índices Basados en la Pendiente


Los índices basados en la pendiente son combinaciones de las bandas roja visible e infrarroja cercana y se usan extensamente para generar índices de vegetación. Los valores indican tanto el estado como la abundancia de la cobertura y biomasa de la vegetación verde. Los índices incluyen el RATIO, NDVI, RVI, NRVI, TVI, CTVI y el TTVI. El módulo VEGINDEX en IDRISI se puede usar para generar una imagen para cada uno de estos índices.

El **Índice de Vegetación de Cociente (RATIO)** fue propuesto por Rouse y colaboradores (1974) para separar la vegetación verde del suelo de fondo usando las imágenes del LANDSAT MSS. El índice RATIO se produce simplemente dividiendo los valores de reflectancia contenidos en la banda infrarroja cercana por aquellos contenidos en la banda roja, es decir:

$$\text{RATIO} = \frac{\text{NIR}}{\text{RED}}$$

El resultado capta claramente el contraste entre las bandas roja e infrarroja para los pixeles de vegetación, con valores de índices altos producidos por combinaciones de reflectancia roja baja (debido a la absorción por parte de la clorofila) e infrarroja alta (como resultado de la estructura de la hoja). Además, ya que el índice se construye como

un coeficiente, los problemas de iluminación variable resultantes de la topografía son minimizados. No obstante, el índice es susceptible a errores de división por cero y la escala de medición resultante no es lineal. Como consecuencia, las imágenes del índice RATIO no poseen distribuciones normales (Figura 19-2), por lo que hacen dificultosa la aplicación de algunos procedimientos estadísticos.



**Figure 19-2.** Histograma de una imagen de Índice de Vegetación de Cociente.

**El Índice de Vegetación de Diferencia Normalizada (NDVI)** también fue introducido por Rouse y colaboradores (1974) para producir un índice espectral que separa la vegetación verde del suelo utilizando datos digitales del LANDSAT MSS. Éste se expresa como la diferencia entre las bandas infrarroja cercana y roja normalizada por la suma de esas bandas, es decir:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Este es el índice más comúnmente usado porque retiene la habilidad para minimizar los efectos topográficos y a su vez producir una escala de medida lineal. Además, los errores de división por cero son reducidos en gran medida. Más aún, la escala de medida posee la apreciada propiedad de oscilar de -1 a 1 con el 0 representando el valor aproximado de la falta de vegetación. Entonces, los valores negativos representan las superficies sin vegetación.

**El Índice de Vegetación Transformado (TVI)** (Deering y colaboradores, 1975) modifica el NDVI agregando una constante de 0,50 a todos sus valores y calculando la raíz cuadrada de los resultados. La constante 0,50 se introduce para evitar operar con valores negativos del NDVI. El cálculo de la raíz cuadrada se emplea para corregir los valores del NDVI que se aproximan a una distribución Poisson e introducir una distribución normal. Con estos dos elementos, el TVI toma la siguiente forma:

$$TVI = \sqrt{\left(\frac{NIR - RED}{NIR + RED}\right) + 0.5}$$

Sin embargo, el uso del TVI requiere que los valores del NDVI de entrada mínima sean mayores que -0,5 para evitar abortar la operación. Los valores negativos aún permanecerán si se hallan valores menores que -0,5 en el NDVI. Es más, no existe una diferencia técnica entre el NDVI y el TVI en términos de la salida de imagen o de la detección activa de vegetación.

**El Índice de Vegetación Transformado Corregido (CTVI)** propuesto por Perry y Lautenschlager (1984) apunta a corregir el TVI. Resulta obvio que agregar una constante de 0,5 a todos los valores del NDVI no siempre elimina los valores negativos porque los valores del NDVI pueden tener el rango -1 a +1. Los valores menores que -0,5 dejan pequeños valores negativos luego de la operación de adición. Entonces, el CTVI se realiza para resolver esta situación al dividir  $(NDVI + 0,50)$  por su valor absoluto  $ABS(NDVI + 0,50)$  y multiplicar el resultado por la raíz cuadrada del valor absoluto  $(SQRT[ABS(NDVI + 0,50)])$ . Esto suprime el NDVI negativo. La ecuación se escribe:

En el caso que la corrección se aplique de manera uniforme, la imagen de salida que usa el CTVI no debe tener diferencia con la imagen inicial NDVI o la TVI cuando el TVI lleva a cabo correctamente la operación de raíz cuadrada. La corrección se realiza para eliminar los valores negativos y generar una imagen del índice de vegetación



similar a, o mejor que, el NDVI. Sin embargo, Thiam (1997) indica que la imagen resultante del CTVI puede ser muy “ruidosa” debido a una sobrestimación de la cualidad verde. Él sugiere ignorar el primer término de la ecuación CTVI para obtener mejores resultados. Esto se logra simplemente sacando la raíz cuadrada de los valores absolutos del NDVI en la expresión original del TVI para tener un nuevo índice de vegetación llamado **Índice de Vegetación Transformado de Thiam (TTVI)**.

$$TTVI = \sqrt{ABS(NDVI + 0.5)}$$

El simple **Índice de Vegetación de Cociente (RVI)** fue sugerido por Richardson y Wiegand (1977) por tener gráficamente la misma fuerzas y debilidades que el TVI (ver arriba) mientras que resulta más simple a nivel computacional. El RVI es claramente el inverso del cociente simple estándar (RATIO) como se muestra en esta expresión:

$$RVI = \frac{RED}{NIR}$$

El **Índice de Vegetación de Cociente Normalizado (NRVI)** es una modificación del RVI por Baret y Guyot (1991) por el cual el resultado del RVI - 1 es normalizado sobre el RVI + 1.


$$NRVI = \frac{RVI - 1}{RVI + 1}$$

Esta normalización es similar en efecto a la del NVDI, es decir, reduce los efectos topográficos, lumínicos y atmosféricos, y crea una distribución normal estadísticamente apreciada.

## Los Índices de Vegetación Basados en la Distancia

Este grupo de índices de vegetación está derivado del Índice de Vegetación Perpendicular (PVI) discutidos con detenimiento más adelante. El objetivo principal de estos índices de vegetación es cancelar el efecto del suelo en los casos donde la vegetación es escasa y los pixeles contienen una mezcla de vegetación verde y suelo de fondo. Esto es particularmente importante en medio ambientes áridos y semiáridos.


El procedimiento está basado en el concepto de la línea del suelo como se señaló antes. La línea del suelo representa una descripción de las firmas típicas de suelos en un esquema biespectral rojo/infrarrojo cercano. Este se obtiene a través de una regresión lineal de la banda infrarroja cercana en contra de la banda roja para una muestra de pixeles de suelo desnudo. Los pixeles que se hallan cerca de la línea del suelo son interpretados como suelos mientras que aquellos lejos de ésta se interpretan como vegetación. Los índices de vegetación basados en la distancia que usan la línea del suelo requieren la pendiente (*b*) y la ordenada al origen (*a*) de la línea como entradas para el cálculo. Desafortunadamente, ha habido una inconsistencia importante en la lógica con la cual se ha desarrollado esta línea del suelo para índices de vegetación específicos. Un grupo requiere la banda roja como la variable dependiente y el otro requiere la banda infrarroja cercana como la variable independiente para la regresión. Se debe consultar el Sistema de Ayuda on-line sobre VEGINDEX para cada índice de vegetación en el grupo de los Basados en la Distancia para indicar cuáles de estos dos enfoques debe usarse.



**Figura 19-3**

La Figura 19-3 muestra la línea del suelo y sus parámetros calculados para un grupo de píxeles de suelo usando el módulo REGRESS en IDRISI. El procedimiento requiere que Ud. identifique un grupo de píxeles de suelo desnudo como una máscara booleana (1=suelo / 0=otro). REGRESS se emplea entonces para calcular la regresión entre la banda roja y la infrarroja cercana (o viceversa, dependiendo del índice), y luego usar esta máscara para definir los píxeles a partir de los cuales se debe definir la pendiente y la ordenada al origen. Un ejemplo elaborado de este procedimiento se puede hallar en el **Tutorial** en el ejercicio Vegetation Analysis in Arid Environments (Análisis de la Vegetación en Ambientes Áridos).

El **Índice de Vegetación Perpendicular (PVI)** sugerido por Richardson y Wiegand (1977) es el índice principal del cual se deriva todo este grupo. El PVI emplea la distancia perpendicular desde cada coordenada de píxel (Ej.: Rp5,Rp7) hasta la línea del suelo como se indica en la Figura 19-4.



**Figura 19-4.** El Índice de Vegetación Perpendicular (de Richardson y Wiegand, 1977).

Para derivar esta distancia perpendicular, se necesitan cuatro pasos:

1. Determinar la ecuación de la línea del suelo estimando la regresión entre los valores de la reflectancia del suelo desnudo para la banda roja (variable dependiente) versus la infrarroja (variable independiente).<sup>81</sup> Esta ecuación será en la forma de:

<sup>81</sup> Verifique el Sistema de Ayuda on-line de cada índice para determinar cuál banda debe usarse como la variable dependiente y cuál como la independiente. En este ejemplo, para el PVI, la roja es la dependiente y la infrarroja es la independiente.

$$Rg5 = a_0 + a_1 Rg7$$

Donde  $Rg5$  es una posición Y en la línea del suelo

$Rg7$  es la coordenada X correspondiente

$a_1$  es la pendiente de la línea del suelo

$a_0$  es la ordenada al origen Y de la línea del suelo

2. Determinar la ecuación de la línea perpendicular a la línea del suelo. Esta ecuación tiene la forma:

$$Rp5 = b_0 + b_1 Rp7$$

Donde  $b_0 = Rp5 - b_1 Rp7$

Donde

$Rp5$  = reflectancia roja

$Rp7$  = reflectancia infrarroja

y

$$b_1 = -1/a_1$$

donde

$a_1$  = la pendiente de la línea del suelo

3. Encontrar la intersección de estas dos líneas (es decir, la coordenada  $Rgg5, Rgg7$ ).

$$Rgg5 = \frac{b_1 a_0 - b_0 a_1}{b_1 - a_1}$$


$$Rgg7 = \frac{a_0 - b_0}{b_1 - a_1}$$

4. Encontrar la distancia entre la intersección ( $Rgg5, Rgg7$ ) y la coordenada del pixel ( $Rp5, Rp7$ ) usando el Teorema de Pitágoras.

$$PVI = \sqrt{(Rgg5 - Rp5)^2 + (Rgg7 - Rp7)^2}$$

Los intentos para mejorar la ejecución del PVI han producido otros tres sugeridos por Perry y Lautenschlager (1984), Walther y Shabaani (1991), y Qi y colaboradores (1994). Para evitar la confusión, los PVIs derivados están indexados del 1 al 3 (PVI1, PVI2, PVI3).

**PVI<sub>1</sub>** fue desarrollado por Perry y Lautenschlager (1984) quienes discutían que la ecuación original del PVI era intensiva a nivel computacional y no discriminaba entre píxeles que se hallan a la izquierda o derecha de la línea del suelo (es decir, el agua de la vegetación). Con un patrón de respuesta espectral de vegetación en el cual la reflectancia infrarroja es mayor a la roja, todos los píxeles de vegetación se hallan a la derecha de la línea del suelo (Ej.: pixel 2 en la Figura 19-5). En algunos casos, un pixel que no representa vegetación (Ej.: agua) puede estar igualmente lejos de la línea del suelo, pero se halla hacia la izquierda de ésta (Ej.: pixel 1 en la Figura 19-5). En el caso del PVI, a ese pixel de agua se le asignará un valor de índice de vegetación alto. El PVI1 asigna valores negativos a aquellos píxeles que se encuentran a la izquierda de la línea del suelo.



**Figura 19-5.** Distance desde la línea de Suelo.

La ecuación se escribe:

$$PVI_1 = \frac{(bNIR - RED + a)}{\sqrt{b^2 + 1}}$$

donde

NIR	=	reflectancia en la banda infrarroja cercana
RED	=	reflectancia en la banda roja visible
a	=	ordenada al origen de la línea del suelo
b	=	pendiente de la línea del suelo

**PVI<sub>2</sub>** (Walther y Shabaani, 1991; Bannari y colaboradores, 1996) pondera la banda roja con la ordenada al origen de la línea del suelo y se escribe<sup>82</sup>

$$PVI_2 = \frac{NIR - a * Red + b}{\sqrt{1 + a^2}}$$

donde

NIR	=	reflectancia en la banda infrarroja cercana
RED	=	reflectancia en la banda roja visible
a	=	ordenada al origen de la línea del suelo
b	=	pendiente de la línea del suelo

**PVI<sub>3</sub>**, presentado por Qi y colaboradores (1994), se escribe:

$$PVI_3 = apNIR - bpRED$$

donde

<i>p</i> NIR	=	reflectancia en la banda infrarroja cercana
<i>p</i> RED	=	reflectancia en la banda roja visible
a	=	ordenada al origen de la línea del suelo
b	=	pendiente de la línea del suelo

<sup>82</sup> En Bannari y colaboradores (1996), **a** se usa para designar la pendiente y **b** para designar la ordenada al origen. Más comúnmente en la regresión lineal, **a** es la ordenada al origen y **b** la pendiente de la línea adecuada. Aquí, esto ha sido corregido.

**Índice de Vegetación de Diferencia (DVI)** también es sugerido por Richardson y Wiegand (1977) como un algoritmo para el cálculo del índice de vegetación más fácil. La particularidad del DVI es que pesa la banda infrarroja cercana por la pendiente de la línea del suelo. Éste se escribe:

$$DVI = g \text{ MSS7} - \text{MSS5}$$

donde

$g$	=	la pendiente de la línea del suelo
$\text{MSS7}$	=	reflectancia en la banda 2 infrarroja cercana
$\text{MSS5}$	=	reflectancia en la banda roja visible


De manera similar al PVI1, con el DVI, un valor de cero indica suelo desnudo, los valores menores que cero indican agua y aquellos mayores que cero indican vegetación.

El **Índice de Vegetación Ashburn (AVI)** (Ashburn, 1978) se presenta como una medida de la vegetación creciente verde. Los valores en MSS7 se multiplican por 2 para escalar los valores de datos de 6 bits de este canal de manera que coincidan con los valores de 8 bits del MSS5. La ecuación se escribe:

$$AVI = 2.0 \text{ MSS7} - \text{MSS5}$$

Este factor de escala no se aplica cuando ambas bandas son de 7 u 8 bits y la ecuación se rescribe como una simple resta.

El **Índice de Vegetación Ajustado al Suelo (SAVI)** es propuesta por Huete (1988). Está preparado para minimizar los efectos del fondo de suelo sobre la señal de vegetación al incorporar un factor  $L$  de ajuste del suelo constante en el denominador de la ecuación NDVI.  $L$  varía con las características de reflectancia del suelo (Ej.: color y brillo). Huete (1988) provee un gráfico de donde se pueden extraer los valores de  $L$  (Figura 19-6). El factor  $L$  elegido depende de la densidad de la vegetación que uno desea analizar. Para un nivel de densidad muy pobre, Huete y colaboradores (1988) sugieren usar un factor  $L$  de 1,0; para un nivel intermedio, 0,5 y para uno alto, 0,25. Walther y Shabaani (1991) proponen que el mejor valor  $L$  para seleccionar es donde la diferencia entre los valores de SAVI para suelos oscuros (dark soil) y claros (light soil) es mínima. Para  $L = 0$ , SAVI es igual a NDVI. Para  $L = 100$ , SAVI se aproxima a PVI.



**Figura 19-6.** Influencia de suelos claros y oscuros sobre los valores SAVI de algodón como una función del factor  $L$  cambiado (de Huete, 1988).

La ecuación se escribe:

$$SAVI = \frac{\rho_{nir} - \rho_{red}}{(\rho_{nir} + \rho_{red} + L)} \cdot (1 + L)$$

donde

$\rho_{nir}$  = banda infrarroja cercana

$\rho_{red}$  = banda roja visible

$L$  = factor de ajuste del suelo

El **Índice de Vegetación Ajustado al Suelo Transformado (TSAVI<sub>1</sub>)** fue definido por Baret y colaboradores (1989) quienes discutían que el concepto de SAVI es exacto **sólo** si las constantes de la línea del suelo son  $a=1$  y  $b=0$  (observe la inversión de estos símbolos comunes). Debido a que este no es generalmente el caso, ellos transformaron el SAVI. Tomando en cuenta el concepto PVI, ellos propusieron una primera modificación de TSAVI designado como TSAVI<sub>1</sub>.

La expresión transformada es la siguiente:

$$TSAVI_1 = \frac{a(NIR - a * Red - b)}{(Red + a * NIR - a * b)}$$

donde

NIR = reflectancia en la banda infrarroja cercana (expresada como reflectancias)

RED = reflectancia en la banda roja visible (expresada como reflectancias)

$a$  = pendiente de la línea del suelo

$b$  = ordenada al origen de la línea del suelo

Con algo de resistencia a la humedad del suelo alta, el TSAVI<sub>1</sub> puede ser un muy buen candidato para emplear en mregiones semiáridas. El TSAVI<sub>1</sub> fue específicamente diseñado para regiones semiáridas y no funciona bien en áreas con vegetación densa.

El TSAVI fue reajustado una segunda vez por Baret y colaboradores (1991) con un factor de corrección aditiva de 0,08 para minimizar los efectos del suelo. La nueva versión se llama **TSAVI<sub>2</sub>** y está dada por:

$$TSAVI_2 = \frac{a(NIR - aRED - b)}{RED + aNIR - ab + 0.08(1 + a^2)}$$

**Los Índices de Vegetación Ajustados al Suelo Modificados (MSAVI<sub>1</sub> y MSAVI<sub>2</sub>)** propuesto por Qi y colaboradores (1994) se basan en una modificación del factor  $L$  del SAVI. Ambos están diseñados para corregir mejor el brillo del fondo de suelo en condiciones diferentes de cobertura vegetal.

Con el MSAVI<sub>1</sub>,  $L$  es seleccionado como una función empírica debido al hecho de que  $L$  disminuye con una cobertura de vegetación decreciente al igual que en tierras semiáridas (Qi y colaboradores, 1994). Para cancelar o minimizar el efecto del suelo,  $L$  se establece como el producto de NDVI y WDV (descripto abajo). Por lo tanto, emplea las tendencias opuestas de NDVI y WDV. La expresión completa de MSAVI<sub>1</sub> se escribe:

$$MSAVI_1 = \frac{NIR - RED}{NIR + RED + L} \cdot (1 + L)$$

donde

NIR = reflectancia en la banda infrarroja cercana

NIR = reflectancia en la banda roja visible

$L = 1 - 2\gamma NDVI * WDV$

Donde

NDVI = Índice de Vegetación de Diferencia Normalizada

WDVI = Índice de Vegetación de Diferencia Ponderada

$\gamma$  = pendiente de la línea del fondo de suelo

2 = usado para aumentar el rango dinámico de L

rango de L = 0 a 1

El segundo SAVI modificado, el MSAVI<sub>2</sub>, emplea un factor  $L$  inductivo para:

1. eliminar el “ruido” del suelo que no ha sido cancelado por el producto de NDVI por WDVI, y
2. corregir los valores mayores que 1 que puede tener el MSAVI<sub>1</sub> debido al bajo valor negativo de NDVI \* WDVI. Entonces, su uso está limitado a áreas de alta densidad de vegetación.

La expresión general del MSAVI<sub>2</sub> es:

$$\text{MSAVI}_2 = \frac{2\rho_{\text{nir}} + 1 - \sqrt{(2\rho_{\text{nir}} + 1)^2 - 8(\rho_{\text{nir}} - \rho_{\text{red}})}}{2}$$

donde

$\rho_{\text{NIR}}$  = reflectancia de la banda infrarroja cercana  
 $\rho_{\text{RED}}$  = reflectancia de la banda roja

El **Índice de Vegetación de Diferencia Ponderada (WDVI)** se ha atribuido a Richardson y Wiegand (1977), y Clevers (1978) por Kerr y Pichon (1996), cuya expresión se escribe:

$$\text{WDVI} = \rho_n - \gamma \rho_r$$

Donde

$\rho_n$  = reflectancia de la banda infrarroja cercana

$\rho_r$  = reflectancia de la banda roja visible

$\gamma$  = pendiente de la línea del suelo

Aunque parezca simple, el WDVI es tan eficiente como la mayoría de los índices basados en la pendiente. El efecto de ponderar la banda roja con la pendiente de la línea del suelo es la maximización de la señal de vegetación en la banda infrarroja cercana y la minimización del efecto del suelo.

## Las Transformaciones Ortogonales

La derivación de los índices de vegetación también ha sido abordada a través de técnicas de transformación ortogonal tales como el PCA, la GVI de la Transformación Tasseled Cap de Kauth-Thomas y la MGVI de la transformación ortogonal de Wheeler-Misra. El lazo entre estas tres técnicas es que todas expresan la vegetación verde a través del desarrollo de su segundo componente.

**Análisis de los Componentes Principales (PCA)** es una transformación ortogonal de datos de imágenes  $n$ -dimensionales que produce un nuevo grupo de imágenes (componentes) que no tienen correlación entre sí y están

ordenadas con respecto a la cantidad de variación (información) del grupo original de imágenes que éstas representan. El PCA es generalmente empleado para descubrir la dimensionalidad subyacente de los datos multivariados al eliminar la redundancia (evidente en la intercorrelación de los valores de los píxeles de imágenes), con aplicaciones específicas en SIG y en el procesamiento de imágenes que van desde la compresión de datos hasta el análisis de series de tiempo. En el contexto de las imágenes de sensores remotos, el primer componente usualmente representa el albedo (en el cual está representado el fondo del suelo), mientras que el segundo componente la mayoría de las veces representa variaciones en la cobertura de la vegetación. Por ejemplo, el componente 2 generalmente tiene cargas positivas en las bandas infrarrojas cercanas y cargas negativas en las bandas rojas visibles. Como resultado, el patrón de vegetación verde está resaltado en este componente (Singh y Harrison, 1985; Fung y LeDrew, 1987; Thiam, 1997). Esto se ilustra en la Tabla 19-1 correspondiente a las cargas factoriales de una imagen MSS de 1990 del sur de Mauritania.

	Comp1	Comp2	Comp3	Comp4
MSS1	0.86	-0.46	-0.22	0.01
MSS2	0.91	-0.36	0.19	-0.08
MSS3	0.95	0.25	0.09	0.14
MSS4	0.75	0.65	-0.08	-0.09

**Tabla 19-1 Cargas de factores del PCA de 1990**

El **Índice de Vegetación Verde (GVI)** del Tasseled Cap es la segunda de las cuatro bandas nuevas que Kauth y Thomas (1976) extrajeron de imágenes crudas MSS. El GVI provee coeficientes globales que son utilizados para pesar las cuentas digitales del MSS original para generar las nuevas bandas transformadas. El módulo TASSCAP en IDRISI correspondiente al GVI es xxverde (xx = el prefijo de dos caracteres ingresado por el usuario) por defecto. La expresión de la banda del índice de vegetación verde, GVI, se escribe de la siguiente manera para datos MSS o TM:

$$\text{GVI} = [(-0,386\text{MSS4}) + (-0,562\text{MSS5}) + (0,600\text{MSS6}) + (0,491\text{MSS7})]$$

$$\text{GVI} = [(-0,2848\text{TM1}) + (-0,2435\text{TM2}) + (-0,5436\text{TM3}) + (0,7243\text{TM4}) + (0,0840\text{TM5}) + (-0,1800\text{TM7})]$$

Los pesos negativos del GVI sobre las bandas visibles tienden a minimizar los efectos del fondo de suelo, mientras que los pesos positivos en las bandas infrarrojas cercanas enfatizan la señal de vegetación verde.

**Índice de Vegetación Verde de Misra (MGVI)** es el equivalente al GVI Tasseled Cap y es propuesto por Wheeler y colaboradores (1976) y Misra y colaboradores (1977) como un índice de vegetación espectral. Es la segunda de las cuatro nuevas bandas producidas a partir de una aplicación del Análisis de Componentes Principales a las cuantas digitales MSS.

La expresión algebraica del MGVI es:

$$\text{MGVI} = -0,386\text{MSS4} - 0,530\text{MSS5} + 0,535\text{MSS6} + 0,532\text{MSS7}$$

El principio del MGVI es pesar las cuentas digitales originales con algunos coeficientes globales provistos por Wheeler y Misra para generar un segundo Componente Principal. Sin embargo, el uso de estos coeficientes globales puede que no produzca los mismos resultados como un segundo Componente Principal directamente calculado, ya que pueden ser específicos de un sitio. Los coeficientes corresponden a los vectores propios (*vector propios*) producidos con un Análisis de Componentes Principales. Los vectores propios indican la dirección de los ejes principales (Mather, 1987). Éstos se combinan con los valores espectrales originales para regenerar los Componentes Principales. Por ejemplo, el PCA1 es producido al combinar las reflectancias originales con los vectores propios (valores de las columnas) asociados con el componente 1. De manera similar, el componente 2 (MGVI) es producido al combinar las cuentas digitales originales con los vectores propios asociados con el componente 2 como se resalta en la Tabla 19-2.



	Comp1	Comp2	Comp3	Comp4
eigvec.1	0.49	-0.51	-0.70	0.08
eigvec.2	0.52	-0.40	0.60	-0.45
eigvec.3	0.55	0.28	0.27	0.74
eigvec.4	0.43	0.71	-0.27	-0.49

**Tabla 19-2 Vectores propios del PCA de 1990**

El módulo PCA en IDRISI genera vectores propios así como también cargas de factores con las imágenes componentes.

Una imagen MGVI de sitio específico puede ser producida entonces con el Image Calculator usando los valores de vectores propios adecuados. La siguiente ecuación se usaría para producir la imagen MGVI para el ejemplo mostrado en la Tabla 19-2:

$$MGVI90 = (-0,507MSS4) + (-0,400MSS5) + (0,275MSS6) + (0,712MSS7)$$

## Resumen

El uso de cualquiera de estas transformaciones depende del objetivo de la investigación y de las características geográficas generales del área de aplicación. En teoría, cualquiera de ellas se puede aplicar en cualquier área geográfica, sin importar su sensibilidad a varios componentes ambientales que pueden limitar su efectividad. Con respecto a esto, uno puede considerar la aplicación de los índices basados en la pendiente porque son simples de usar y producen resultados numéricos fáciles de interpretar. No obstante, incluyendo el reconocido NDVI, todos tienen una debilidad principal que es la incapacidad de minimizar los efectos del fondo de suelo. Esto significa que una cierta proporción de sus valores, negativos o positivos, representa el brillo del suelo. El efecto del suelo de fondo es un factor limitante principal para ciertos análisis estadísticos dedicados a la evaluación cuantitativa de la biomasa verde que se encuentra sobre el suelo.

Aunque producen índices cuyos extremos pueden ser mucho más bajos o altos que los del índice más familiar NDVI, los índices basados en la distancia tienen la ventaja de minimizar los efectos del suelo. Esta minimización es desempeñada por la combinación de las bandas de entrada con la pendiente y la ordenada al origen de la línea del suelo obtenida a través de una regresión lineal entre los valores de reflectancia de la muestra de suelo desnudo extraídos de las bandas rojas e infrarrojas cercanas. Esto representa un avance cuantitativo y cualitativo importante del significado de los índices para todo tipo de aplicaciones, particularmente para aquellas que tratan ambientes áridos y semiáridos. Sin embargo, para sacar ventaja de esto Ud. debe ser capaz de identificar los píxeles de suelo desnudo en la imagen.

Los índices ortogonales, el Tasseled Cap, el Análisis de los Componentes Principales y la transformación de Misra-Wheeler (MGVI), realizan una correlación inversa de las bandas originales a través de una ortogonalización para extraer nuevas bandas. Con este proceso, producen una banda verde que, en cierta forma, está libre de los efectos del fondo de suelo, ya que casi todas las características del suelo son atribuidas a otra banda nueva llamada brillo.

A pesar del gran número de índices de vegetación actualmente en uso, resulta claro que se necesita aprender mucho acerca de la aplicación de estos procedimientos en diferentes ambientes. Por esto los módulos VEGINDEX y TASSCAP han sido creados. Sin embargo, también resulta evidente que la percepción remota ofrece una oportunidad significativa para estudiar y monitorear la vegetación y su dinámica.

## Referencias

- Ashburn, P., 1978. The vegetative index number and crop identification, *The LACIE Symposium Proceedings of the Technical Session*, 843-850.
- Bannari, A., Huete, A. R., Morin, D., y Zagolski, 1996. Effets de la Couleur et de la Brilliance du Sol Sur les Indices de Végétation, *International Journal of Remote Sensing*, 17(10): 1885-1906.
- Baret, F., Guyot, G., y Major, D., 1989. TSAVI: A Vegetation Index Which Minimizes Soil Brightness Effects on LAI and APAR Estimation, 12th *Canadian Symposium on Remote Sensing and IGARSS'90*, Vancouver, Canadá, 4.
- Baret, F., and Guyot, G., 1991. Potentials and Limits of Vegetation Indices for LAI and APAR Assessment, *Remote Sensing and the Environment*, 35: 161-173.
- Deering, D. W., Rouse, J. W., Haas, R. H., y Schell, J. A., 1975. Measuring "Forage Production" of Grazing Units From LANDSAT MSS Data, *Proceedings of the 10th International Symposium on Remote Sensing of Environment*, II, 1169-1178.
- Fung, T., y LeDrew, E., 1988. The Determination of Optimal Threshold Levels for Change Detection Using Various Accuracy Indices, *Photogrammetric Engineering and Remote Sensing*, 54(10): 1449-1454.
- Huete, A. R., 1988. A Soil-Adjusted Vegetation Index (SAVI), *Remote Sensing and the Environment*, 25: 53-70.
- Jackson, R. D., 1983. Spectral Indices in n-Space, *Remote Sensing and the Environment*, 13: 409-421.
- Kauth, R. J., y Thomas, G. S., 1976. The Tasseled Cap - A Graphic Description of the Spectral Temporal Development of Agricultural Crops As Seen By LANDSAT. *Proceedings of the Symposium on Machine Processing of Remotely Sensed Data*, Purdue University, West Lafayette, Indiana, 41-51.
- Kogan, F. N., 1990. Remote Sensing of Weather Impacts on Vegetation in Nonhomogeneous Areas, *International Journal of Remote Sensing*, 11(8): 1405-1419.
- Liu, W. T., y Kogan, F. N., 1996. Monitoring Regional Drought Using the Vegetation Condition Index, *International Journal of Remote Sensing* 17(14): 2761-2782.
- Misra, P. N., y Wheeler, S.G., 1977. LANDSAT Data From Agricultural Sites - Crop Signature Analysis, *Proceedings of the 11th International Symposium on Remote Sensing of the Environment*, ERIM.
- Misra, P. N., Wheeler, S. G., y Oliver, R. E., 1977. Kauth-Thomas Brightness and Greenness Axes, IBM personal communication, Contract NAS-9-14350, RES 23-46.
- Perry, C. Jr., y Lautenschlager, L. F., 1984. Functional Equivalence of Spectral Vegetation Indices, *Remote Sensing and the Environment* 14: 169-182.
- Qi, J., Chehbouni A., Huete, A. R., Kerr, Y. H., y Sorooshian, S., 1994. A Modified Soil Adjusted Vegetation Index. *Remote Sensing and the Environment*, 48: 119-126.
- Richardson, A. J., y Wiegand, C. L., 1977. Distinguishing Vegetation From Soil Background Information, *Photogrammetric Engineering and Remote Sensing*, 43(12): 1541-1552.
- Rouse, J. W. Jr., Haas, R., H., Schell, J. A., y Deering, D.W., 1973. Monitoring Vegetation Systems in the Great Plains with ERTS, *Earth Resources Technology Satellite-1 Symposium*, Goddard Space Flight Center, Washington D.C., 309-317.
- Rouse, J. W. Jr., Haas, R., H., Deering, D. W., Schell, J. A., y Harlan, J. C., 1974. Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation. NASA/GSFC Type III Final Report , Greenbelt, MD., 371.
- Singh, A., y Harrison, A., 1985. Standardized Principal Components, *International Journal of Remote Sensing*, 6(6): 883-896.

Thiam, A.K. 1997. *Geographic Information Systems and Remote Sensing Methods for Assessing and Monitoring Land Degradation in the Sahel: The Case of Southern Mauritania*. Doctoral Dissertation, Clark University, Worcester Massachusetts.

Tripathy, G. K., Ghosh, T. K., y Shah, S. D., 1996. Monitoring of Desertification Process in Karnataka State of India Using Multi-Temporal Remote Sensing and Ancillary Information Using GIS, *International Journal of Remote Sensing*, 17(12): 2243-2257.

# CAPÍTULO 19 - Análisis e Imágenes RADAR

El término RADAR es una sigla para Radio Detección y Telemetría. Las imágenes RADAR usan ondas de radio para detectar características de la superficie. Hay un número de instrumentos de percepción RADAR que proveen un rango de productos de datos a la comunidad del usuario. Estos incluyen: ERS (Satélite Europeo de Percepción Remota), JERS (Satélite Japonés de Recursos Terrestres) y el RADARSAT Canadiense. RADARSAT es un sistema comercial (a diferencia de los otros sistemas que son en gran medida misiones científicas) diseñado para proveer datos para un amplio rango de usos.

Los sistemas ópticos de percepción remota multiespectral como el LANDSAT y el SPOT reúnen datos en forma de energía electromagnética reflejada. La fuente de energía de estos sensores es el sol. A diferencia de estos sistemas ópticos pasivos, los sistemas RADAR como el RADARSAT son sistemas activos de percepción, es decir que éstos proveen la energía que luego es medida cuando regresa al sensor. Los sistemas RADAR usan energía transmitida en frecuencias de microondas no detectables por el ojo humano. La mayoría de los sistemas RADAR funcionan en una sola frecuencia. El RADARSAT, por ejemplo, opera en lo que se conoce como frecuencia de banda C<sup>83</sup> (frecuencia 5,3 Ghz o longitud de onda 5,6 cm.) y por lo tanto adquiere datos de una sola banda. El instrumento de percepción empleado por el RADARSAT se conoce como Radar de Apertura Sintética (SAR). Este instrumento usa el movimiento del satélite y el cambio de frecuencia doppler para sintetizar electrónicamente la gran antena requerida para la adquisición de imágenes RADAR de resolución elevada. El sensor envía un pulso de energía microonda a la tierra y toma el tiempo que le lleva al pulso regresar luego de la interacción con la superficie terrestre.

## La Naturaleza de los Datos RADAR: Ventajas y Desventajas

Como el RADARSAT-SAR utiliza energía microonda, es capaz de penetrar las barreras atmosféricas que a menudo entorpecen la realización de imágenes ópticas. El SAR puede “ver” a través de nubes, lluvia, neblina y polvo, y puede funcionar en la oscuridad, haciendo posible la captación de datos bajo cualquier condición atmosférica. Debido a que la energía microonda puede penetrar la superficie terrestre para apreciar las profundidades, ésta resulta útil en ambientes áridos. Adicionalmente, la energía microonda es más apropiada para estudiar las condiciones y las propiedades de los niveles subterráneos relevantes para el pronóstico de recursos y las exploraciones arqueológicas. Los datos reunidos por este sensor son de la forma conocida como datos polarizados HH (transmisión horizontal, recepción horizontal)<sup>84</sup>. La señal enviada a la superficie terrestre tiene una orientación horizontal (o polarización) y es captada con la misma polarización. Las variaciones en el haz de retorno, llamado *dispersión inversa*, se producen a partir de condiciones variables en las rugosidades de la superficie, la topografía y la humedad de la superficie. Estas características de la señal del RADAR se pueden explotar, a diferencia de la señal de reflexión simple de la percepción óptica, para inferir las características estructurales y de textura de los objetos meta. El RADARSAT-SAR recolecta datos en una variedad de modos de haces dando lugar a una elección de ángulos de incidencia y resoluciones (desde 20m hasta 100m). Como el instrumento puede ser navegado para observar la misma ubicación desde diferentes posiciones de haces, puede adquirir datos en pares estéreo que se pueden emplear en un gran número de necesidades de los análisis de terreno y topográficos.

Existen, sin embargo, algunos problemas que son exclusivos de las imágenes RADAR. La mayoría, o mejor dicho la totalidad, de las imágenes RADAR tiene una apariencia salpicada o granulosa. Esto es el resultado de una combinación de múltiples dispersiones dentro de un pixel dado. En términos del RADAR, un gran número de materiales de la superficie exhiben patrones de reflectancia *difusa*. Los campos, suelos pantanosos y las canopias boscosas, por ejemplo, muestran retornos de señal alta, mientras que las superficies como los caminos, pavimentos y superficies de agua suave muestran patrones de reflectancia *especular* con retornos de señal baja. Una mezcla de tipos de cobertura terrestre diferentes genera una superficie de imagen compleja. Los datos son entonces inherentemente “ruidosos” y necesitan un procesamiento sustancial antes de usarse en una tarea de análisis dada. En terrenos montañosos, ocurren desplazamientos de sombras o relieve debido a que el pulso RADAR reflejado desde la cima del borde de una montaña alcanza la antena antes que el pulso de la base o del lado opuesto de la montaña. Esto se denomina *efecto de recubrimiento* y es relevante en las áreas con pendientes profundas. Si las pendientes que

<sup>83</sup> Otras frecuencias RADAR incluyen banda X 12,5-8,0 Ghz (2,4 – 3,75 cm.), banda L : 2,0-1,0 Ghz (15-30 cm.) y la banda P 1,0-0,3 Ghz (30-100cm.). La frecuencia de la banda C es 8,0-4,0 Ghz (3,75-7,5 cm.).

<sup>84</sup> Otras opciones son la transmisión vertical, recepción vertical (VV), la transmisión horizontal, recepción vertical (HV) y la transmisión vertical, recepción horizontal (VH).

miran hacia la antena son menos profundas, el pulso alcanza la base antes que la cima. Esto hace que las pendientes parezcan comprimidas en la imagen – efecto conocido como *acercamiento* (*foreshortening*).

En las áreas urbanas, la reflectancia doble de los *reflectores de esquinas* como los edificios produce una apariencia brillante y resplandeciente en la imagen. Mezclada con la reflectancia de las superficies de árboles y caminos, la escena urbana hace que las operaciones de filtrado sean bastante dificultosas. Si un objetivo brillante domina cierta área, puede distorsionar la distribución de los valores de los datos. Debe tenerse en cuenta, no obstante, que las ventajas del RADAR, incluyendo su habilidad para la realización de imágenes en todo tipo de climas, sobrepasan en gran medida sus desventajas.

## Usando Datos RADAR en IDRISI

El módulo llamado RADARSAT se puede usar para importar datos RADARSAT al IDRISI. Es más, las herramientas genéricas de importación de datos de IDRISI se pueden usar para importar la mayoría de los otros formatos. Como cada escena es una sola banda, ésta se puede observar más claramente utilizando una paleta de escala de grises. La paleta RADAR en el IDRISI puede ser empleada para ver imágenes RADAR incluyendo aquellas escenas que poseen distribuciones de datos que ejemplifican histogramas distorsionados negativamente. Un método alternativo es generar un histograma, estimar el rango dentro del cual se encuentran la mayoría de los valores de los datos, y estirar la imagen (con STRETCH) hasta ese nivel. Esto funciona muy bien para el análisis visual de los datos. (Vea el ejercicio Image Exploration en el manual **Tutorial**.)

Actualmente, el uso de datos RADAR en análisis ambientales y en el manejo de recursos aún se encuentra en una etapa temprana y es bastante limitado en comparación con el uso generalizado de los datos de imágenes más tradicionales (Ej.: MSS, TM, fotografía aérea). Es probable que ciertas herramientas más sofisticadas para la interpretación de imágenes RADAR evolucionen en los próximos años. Algunas técnicas útiles para trabajar con los datos RADAR (Ej.: filtros espaciales kernel) han sido registrados en la literatura sobre el RADAR.

Para facilitar el procesamiento y la interpretación de los datos RADAR, IDRISI brinda un módulo de análisis de textura (TEXTURE) y varias opciones en el módulo FILTER, incluyendo el Filtro de Caja Adaptable (Adaptive Box Filter).

Estos procedimientos de filtrado se pueden emplear para minimizar algunos de los efectos de “ruido” salpicado en las imágenes RADAR (pero no pueden eliminarse por completo) y además proveen una interpretación cuantitativa de las superficies captadas por el RADAR. El filtro de Caja Adaptable, el cual es una adaptación del filtro Lee, está muy recomendado por Eliason y McEwen (1990) para reducir los efectos de salpicado (Figura 18-1). Uno debe experimentar con varios tamaños de filtros kernel y opciones de umbrales para poder lograr buenos resultados. Diferentes filtros pueden funcionar mejor para diferentes escenas, dependiendo de la mezcla de tipos de cobertura de la superficie terrestre en la imagen.




Figura 18-1




Figura 18-2




Figura 18-3

Otro método sugerido para reducir más los efectos de salpicado es *el procesamiento de perspectivas múltiples* (Lillesand y Kiefer, 1987). Éste simplemente implica promediar (con OVERLAY o Image Calculator) escenas de la misma área, adquiridas en diferentes ángulos de incidencia, para producir una imagen más suave.

Las imágenes de vista rápida se pueden generar con el filtro MEAN en el IDRISI (Figura 18-2) con el fin de mejorar algunas de las características en las escenas de las imágenes para poder seleccionar sitios para un análisis detallado.

Los filtros Detector de Bordes Sobel, Paso Alto y Mejoramiento de Bordes Laplaciano son útiles para detectar bordes y características lineales en la imagen. Las líneas por defecto, los patrones de drenaje de superficie, los pliegues, los caminos y los límites de tierra/agua son útiles en varias aplicaciones geológicas, de manejo de recursos y en una variedad de aplicaciones ambientales y de planeamiento. Observe además que los filtros definidos por el usuario pueden ser adaptados para cubrir necesidades específicas usando tanto el kernel de 3x3 como el kernel de tamaño variable en el módulo FILTER del IDRISI. Vea la descripción del módulo FILTER en el Sistema de Ayuda on-line para obtener una explicación detallada de estas técnicas de filtrado.

Como se mencionó anteriormente, la señal de *dispersión inversa* del RADAR está compuesta por varias respuestas difusas y especulares de los elementos de escena hasta por los pulsos RADAR enviados. El patrón compuesto de las respuestas de superficie variables se puede explotar para determinar las características de textura de la superficie terrestre. Estas características se pueden derivar con el módulo TEXTURE del IDRISI. Éste incluye tres categorías de análisis. La primera usa la variabilidad en una ventana móvil para determinar varias medidas diferentes, incluyendo la entropía. La segunda estima la dimensión fractal de la superficie de la imagen. La tercera provee filtros direccionales de mejoramiento de bordes para perfeccionar los patrones de bordes en diferentes direcciones. Por ejemplo, la Figura 18-3 muestra una superficie fractal derivada con el módulo TEXTURE. Cada una de las superficies derivadas del TEXTURE se puede usar como entrada en un esquema de clasificación para las imágenes RADAR. Entonces, en lugar de usar respuestas espectrales, uno utiliza en la clasificación características de textura de la escena.

El ciclo repetitivo de 24 días del RADARSAT se puede explotar en el monitoreo de fenómenos de la superficie que exhiben una variabilidad temporal porque cada paso de tiempo tiene una señal de *dispersión inversa* RADAR diferente. Al usar la rutina COMPOSITE del IDRISI, las imágenes RADAR multitemporales se pueden combinar para producir un compuesto en falso color (muy similar a los datos de escena simple multiespectral) que muestra las transiciones temporales en ciertos componentes de la superficie terrestre como los cereales o diferentes tipos de vegetación o de cobertura de la superficie.

Se anticipa que como los datos RADAR cada vez son más usados, se llevarán a cabo desarrollos complementarios en software para explotar el carácter único de las imágenes RADAR.

## Referencias

Eliason, E. M., y McEwen, A. S., 1990. Adaptive Box Filters for Removal of Random Noise from Digital Images, *Photogrammetric Engineering and Remote Sensing*, 56(4): 453-458.

Lillesand, T., y Kiefer, R. W., 1987. *Remote Sensing and Image Interpretation*, John Wiley e Hijos, Nueva York, 472-524.

RADARSAT International, 1995. *RADARSAT Guide to Products and Services*, RADARSAT International, Richmond, B.C., Canadá.

# CAPÍTULO 20 - Análisis de Cambios

Este capítulo brinda un breve pantallazo de los procedimientos especiales disponibles en IDRISI para el análisis de cambios.

El cambio no solo implica una diferencia en las características de la superficie terrestre entre dos fechas, sino que además la diferencia no es característica de la variación normal que puede llegar a encontrarse de un período de tiempo a otro. Es más, la palabra generalmente implica algún tipo de permanencia en la característica cambiada. El análisis de series de tiempo se ocupa de examinar los cambios en una secuencia de imágenes (no solo en dos). Aquí se usa para referirse no solo a la percepción de tendencias en los cambios sino también a la descripción de los valores característicos y a la abstracción de anomalías. Por ejemplo, un examen de deforestación entre dos fechas sería un análisis de cambios, mientras que la búsqueda de evidencias del calentamiento global en los últimos cincuenta años sería un análisis de series de tiempo. Parecería que la diferencia entre el análisis de cambios y el de series de tiempo consiste en si el análisis compara dos imágenes o imágenes múltiples. Sin embargo, el enfoque analítico de ambos a menudo difiere considerablemente.

Con las imágenes SIG y las de sensores remotos, nuestro análisis de cambios puede ocuparse de dos tipos básicos de datos: cualitativos y cuantitativos. Los cualitativos representan las diferencias de clase, mientras que los cuantitativos representan aquellas diferencias de grado. Entonces, por ejemplo, un mapa de usos del terreno contiene datos cualitativos, mientras que un modelo de elevación digital (mapa con relieve topográfico) contiene datos cuantitativos. Con los análisis de cambios y de series de tiempo, las técnicas tienden a diferir dependiendo si la naturaleza de los datos es cualitativa o cuantitativa. Además, éstas varían según se trate de comparaciones entre pares (cambio simple) o entre múltiples imágenes (series de tiempo). La siguiente discusión ha sido organizada sobre esta base.

Las técnicas para el análisis de cambios se dividen en tres grandes categorías para este capítulo. La primera contiene técnicas diseñadas para las comparaciones entre pares de imágenes; la segunda está compuesta por técnicas que se ocupan del análisis de tendencias y anomalías de múltiples imágenes (es decir, una serie de tiempo), y la tercera consiste en métodos para la modelación predecible y la evaluación de modelos. En este capítulo cubriremos la comparación entre pares de datos cuantitativos. En IDRISI, utilizamos la función especial Modelador de Cambios en el Terreno (LCM) para la comparación entre pares de datos cuantitativos. Esta función se describe en detalle en el capítulo Modelador de Cambios en el Terreno. Para muchos, el análisis de cambios es sinónimo al análisis de series de tiempo, particularmente en las técnicas usadas para el análisis de tendencias y anomalías entre imágenes múltiples (ej.: una serie de tiempo). IDRISI ofrece una función para este propósito llamada Modelador de Tendencias Terrestres (ETM). La misma se describe en detalle en el capítulo Modelador de Tendencias Terrestres.

## Comparaciones por Pares

Con las comparaciones por pares podemos dividir aún más las técnicas según si son adecuadas para datos cuantitativos o cualitativos. Los datos cuantitativos tienen valores que indican una cantidad o medida, como un NDVI, una precipitación o una reflectancia. Los datos cualitativos tienen valores que indican diferentes categorías, como identificadores de áreas de censo o clases de aprovechamiento del suelo.

## Datos Cuantitativos

### Diferenciación de Imágenes

Con los datos cuantitativos, la forma más simple de realizar un análisis de cambios es la *diferenciación de imágenes*. En IDRISI, esto se puede lograr con el módulo OVERLAY a través de una simple sustracción de una imagen de otra. Sin embargo, a menudo se requiere un segundo paso en el análisis ya que la imagen de diferencia usualmente contiene un amplio rango de valores. Ambos pasos están incluidos en el módulo IMAGEDIFF, el cual produce varios productos de diferencias de imágenes comunes: una imagen de diferencia simple (posterior – anterior), una imagen de cambio del porcentaje (posterior-anterior/anterior), una imagen de diferencia estandarizada (valores z), o una imagen de diferencia estandarizada clasificada (valores z divididos en 6 clases). También se puede especificar imágenes máscara que limitan el área de estudio.

Se debe tener cuidado al elegir un umbral para distinguir el cambio verdadero de la variabilidad natural en cualquiera de estas imágenes de diferencia. No existen guías seguras para esta operación. Un valor comúnmente usado para el umbral es una desviación estándar 1 (STD) (es decir, todas las áreas dentro de la STD 1 son

consideradas como áreas sin cambio y aquellas más allá de la STD 1, tanto en dirección positiva como negativa, son consideradas como áreas de cambio), pero éste se debe utilizar con precaución. Los valores más altos pueden ser más apropiados, y en algunos casos, las rupturas naturales en un histograma de la imagen de diferencia simple o de cambio de porcentaje pueden ser más sensatas como base para elegir los valores del umbral.

## Cociente de Imágenes

Mientras que la diferenciación de imágenes mira la diferencia absoluta entre imágenes, el *cociente de imágenes* mira la diferencia relativa. Nuevamente, esto se puede lograr con el módulo OVERLAY usando la opción ratio (cociente). No obstante, debido a que la escala resultante del cambio relativo no es simétrica con 1 (el valor sin cambios), se recomienda llevar a cabo una transformación logarítmica antes de establecer un umbral para la imagen. El módulo IMAGERATIO ofrece un cociente simple y un resultado de cociente log.

## Diferenciación de Regresión

Una tercera forma de diferenciación se llama *diferenciación de regresión*. Esta técnica debe emplearse cuando se sospecha que el instrumento de medición (Ej.: un satélite sensor) ha cambiado sus características de salida entre las dos fechas que se quieren comparar. Aquí la primera imagen se usa como la variable independiente y la segunda imagen, como la variable dependiente en una regresión lineal. La ordenada al origen y la pendiente de esta regresión expresan la compensación y ganancia requeridas para ajustar la primera imagen de manera que tenga características de medición comparables a la segunda. En efecto, creamos una imagen posterior pronosticada en la que los valores son los que esperamos si no hubiera otro cambio aparte de la compensación y ganancia causadas por los cambios en el sensor.

La ecuación es:

imagen posterior pronosticada = (imagen anterior \* ganancia) + compensación

Con las diferencias del sensor reconocidas, la imagen posterior pronosticada y la imagen posterior real luego pueden ser analizadas para la detección de cambios. Tenga en cuenta que esta técnica puede que no sea válida si las dos imágenes representan condiciones que son, en forma general, muy diferentes entre las dos fechas.

El módulo CALIBRATE automatiza el proceso de ajuste de la imagen. La imagen de entrada (la que se va a calibrar) se usa como la variable independiente y la imagen de referencia se usa como la variable dependiente en la regresión. La imagen de salida es ajustada a las características de la imagen de referencia y por ello se puede usar en una operación de comparación estándar (tal como IMAGEDIFF o IMAGERATIO) con cualquier imagen también basada en esta referencia, incluyendo la imagen de referencia misma.

Observe que CALIBRATE también ofrece opciones para ajustar una imagen al ingresar los valores de compensación y ganancia o los valores de desviación estándar y media.

## Análisis Vectorial de Cambios

Ocasionalmente, uno necesita llevar a cabo comparaciones por pares sobre imágenes multidimensionales. Por ejemplo, uno puede realizar un análisis de cambios entre dos fechas de imágenes satelitales donde cada una es representada por varias bandas espectrales. Para hacer esto, se puede usar el *análisis vectorial de cambios*. Con este análisis, las imágenes de diferencia son creadas para cada una de las bandas correspondientes. Estas imágenes de diferencia luego son multiplicadas al cuadrado y sumadas. La raíz cuadrada del resultado representa la magnitud (magnitud) del vector de cambio. Todas estas operaciones pueden llevarse a cabo con el Image Calculator, o con una combinación de TRANSFORM y OVERLAY. Los valores de las imágenes resultantes están en las mismas unidades que las imágenes de entrada (Ej.: dn).




Figura 20-1



Cuando sólo dos bandas (para cada una de las dos fechas) están involucradas, también es posible crear una imagen de dirección (direction) (que indica la dirección de cambio en el espacio de banda). El módulo CVA calcula tanto imágenes de magnitud como de dirección para pares de imágenes dos bandas. La Figura 20-1 ilustra estos cálculos. La imagen de magnitud se encuentra en las mismas unidades que las bandas de entrada y es la distancia entre las posiciones de la Fecha (date) 1 y la Fecha 2. La imagen de dirección está medida en acimuts de sentido horario desde una línea vertical que se extiende desde la posición de la Fecha 2.

## Datos Cualitativos

### Tabulación Cruzada / Clasificación Cruzada

Con los datos cualitativos, se debe usar el CROSSTAB para el análisis de cambios entre pares de imágenes y, por otra parte, existen varios tipos de producción que pueden resultar útiles. La tabla de tabulación cruzada muestra las frecuencias con las cuales las clases han permanecido iguales (las frecuencias a lo largo de la diagonal) o han cambiado (las frecuencias fuera de la diagonal). El Índice de Acuerdo Kappa (KIA) indica el grado de acuerdo entre los dos mapas, ambos en un sentido general y sobre una base por categoría. Finalmente, la imagen de clasificación cruzada puede ser reclasificada fácilmente como una imagen de cambio o bien como una imagen de acuerdo. Tenga en cuenta que los valores numéricos de las clases de datos deben ser idénticos en ambos mapas de la salida del CROSSTAB para ser significativos.

## Modelación de Cambios Predecibles

En algunos casos, conocer los cambios que han ocurrido en el pasado puede ayudar a predecir cambios futuros. Se ha desarrollado un juego de modelos en IDRISI para proveer las herramientas básicas para la modelación de cambios predecibles de la cobertura terrestre. Estas herramientas están principalmente basadas en el Análisis en Cadena Markov y en los Autómatas Celulares.

## GEOMOD

GEOMOD es un modelo de simulación de cambios en el uso de la tierra que predice la transición de un estado de uso de la tierra a otro estado de uso de la tierra. Es decir, la ubicación de las celdas de la grilla que cambian con el tiempo de un estado a otro. GEOMOD simula el cambio exactamente entre las dos categorías, el estado 1 y estado 2. Por ejemplo, GEOMOD podría utilizarse para predecir las zonas que puedan cambiar de forestales (estado 1) a no forestales (estado 2) en un momento dado. La simulación puede ocurrir ya sea hacia adelante o hacia atrás en el tiempo. La simulación se basa en:

- la especificación de la hora de inicio, tiempo de finalización y el paso del tiempo para la simulación,
- una imagen que muestra la ubicación de los estados 1 y 2 del uso de la tierra a la hora de inicio,
- una imagen de la máscara opcional distinguiendo entre las áreas dentro y fuera de la región de estudio,
- una imagen opcional de la estratificación que muestra el área de estudio dividida en regiones, donde cada región es un estrato,
- una decisión sobre si limitar el cambio simulado a la frontera entre el estado 1 y estado 2,
- un mapa de aptitud para la transición al estado del uso de la tierra \_ 2,
- la cantidad prevista de \_ estados 1 y 2 del uso de la tierra a la hora de finalización.

Una opción adicional permite la creación de una imagen de impacto ambiental para cada paso de tiempo del cambio simulado de la tierra. GEOMOD también puede generar un mapa de impacto acumulativo para toda la duración de la simulación. Estos mapas del impacto muestran la magnitud del cambio a un recurso del medio ambiente en los lugares de cambio de uso de la tierra simulado. Por ejemplo, estos mapas pueden mostrar las emisiones de carbono que resultan de la conversión de bosques a tierras no forestales. Una discusión completa de GEOMOD junto con un papel blanco extenso se puede encontrar en la Ayuda.

## Análisis en Cadena Markov

Un proceso Markoviano es uno en el que el estado de un sistema en tiempo 2 se puede predecir por el estado del sistema en tiempo 1 con una matriz de probabilidades de transición de cada clase de cobertura a cada una de las otras clases de cobertura. El módulo MARKOV se puede emplear para crear dicha matriz de probabilidad de transición. Como entrada, necesita dos mapas de cobertura terrestre. Luego genera las siguientes producciones:

- Una matriz de probabilidad de transición. Ésta es desplegada y almacenada automáticamente. Las probabilidades de transición expresan la probabilidad de que un pixel de cierta clase cambie a cualquier otra clase (o permanezca en la misma) en el próximo período de tiempo.

- Una matriz de áreas de transición. Ésta expresa el área total (en celdas) que se espera cambie en el próximo período de tiempo.

- Un grupo de imágenes de probabilidad condicional – uno para cada clase de cobertura terrestre. Estos mapas expresan la probabilidad de que cada pixel pertenezca a la clase designada en el próximo período de tiempo. Éstos se llaman mapas de probabilidad condicional porque esta probabilidad es condicional en su estado actual.

El STCHOICE es un módulo de decisión de selección estocástica. Dado el grupo de imágenes de probabilidad condicional producido por MARKOV, se puede usar el STCHOICE para producir cualquier número de realizaciones potenciales de los cambios proyectados incluidos en los mapas de probabilidad condicional. Si Ud. intenta esto, sin embargo, encontrará que los resultados no son lo que esperaba. La producción de MARKOV sólo tiene un conocimiento espacial muy limitado. Para mejorar el sentido espacial de estas imágenes de probabilidad condicional (o en realidad, cualquier estadística), use el DISAGGREGATE. Dada una imagen del patrón espacial interno probable de una estadística de área, el DISAGGREGATE redistribuye la estadística de manera tal que ésta siga el patrón sugerido, pero mantiene el total general del área. Luego se puede utilizar el NORMALIZE para asegurar que las probabilidades sumen 1,0 en cada pixel (esto puede necesitar ser aplicado iterativamente con DISAGGREGATE).

## Autómatas Celulares

Uno de los elementos espaciales básicos que motivan la dinámica de muchos eventos de cambio es la proximidad: las áreas tienen una tendencia más alta a cambiar a una clase cuando hay áreas existentes cercanas de la misma clase (es decir, un fenómeno de expansión). Éstas pueden ser modeladas en forma muy efectiva usando autómatas celulares. Un autómata celular es una entidad celular que varía independientemente su estado basándose en su estado previo y en el de sus vecinos inmediatos según una regla específica. Claramente aquí existe una similitud con el proceso Markoviano. La única diferencia es la aplicación de una regla de transición que depende no sólo del estado previo, sino también del estado de los vecinos locales.

Muchas reglas de transición de autómatas celulares se pueden implementar a través de una combinación de FILTER y RECLASS. Tome, por ejemplo, el caso del *Juego de la Vida* de Conway. En esta ilustración hipotética, los autómatas viven o mueren según los siguientes criterios:

- Una celda vacía se torna viva si hay tres autómatas vivos en el vecindad de 3x3 (conocido como la vecindad Moore) rodeando la celda.

- La celda seguirá viva mientras hayan 2 ó 3 vecinos vivos. Si hay menos vecinos vivos, ésta se muere de soledad; si hay más, se muere debido a la competencia por los recursos.

Esto se puede implementar usando el siguiente kernel con el módulo FILTER:

1	1	1
1	10	1
1	1	1

seguido por la siguiente regla de RECLASS:

0-2	=	0
3-4	=	1
4-11	=	0
12-13	=	1
14-18	=	0

El elemento crítico de esta regla es el uso del multiplicador 10 en la celda central. Como resultado del paso del filtro, Ud. sabe que la celda central está ocupada si el resultado es 10 o más. El módulo CELLATOM se puede utilizar para implementar este tipo de regla de Autómatas Celulares. No obstante, un procedimiento de autómatas celulares muy específico en el contexto de la modelación de cambios predecibles en la cobertura terrestre es implementado con el módulo CA\_MARKOV.

CA\_MARKOV toma como entrada el nombre del mapa de cobertura terrestre del cual se deben proyectar los cambios, el archivo de áreas de transición producido por MARKOV a partir del análisis de esa imagen y de una anterior, y una colección (.rgf) de imágenes de adecuación que expresan la adecuación de un pixel para cada uno de los tipos de cobertura terrestre en consideración. Luego éste comienza un proceso iterativo de reasignación de cobertura terrestre hasta que cubre los totales de área predichos por el módulo MARKOV. La lógica usada por el CA\_MARKOV es la siguiente:

- El número total de iteraciones está basado en el número de pasos de tiempo establecido por el usuario. Por ejemplo, si la proyección es para 10 años en el futuro, el usuario puede elegir completar el modelo en 10 pasos.

- Dentro de cada iteración, cada clase de cobertura terrestre usualmente cede parte de su terreno a una o más de las otras clases (y también puede ganar terreno de otras). Entonces bajo la consideración de cada anfitrión dentro cada iteración, las clases reclamantes seleccionan terreno del anfitrión basándose en el mapa de adecuación para la clase reclamante. Como generalmente hay competencia por parcelas específicas de terreno, este proceso de asignación de terreno es llevado a cabo por medio de un procedimiento de asignación multiobjetiva (el módulo MOLA).

- El componente de los Autómatas Celulares se origina en parte en el proceso iterativo de asignación de terreno, y en parte en un paso de filtrado con cada iteración que reduce la adecuación de los terrenos lejanos a las áreas existentes de ese tipo. Por defecto, el módulo usa un filtro de media de 5x5 para lograr esta restricción de contigüidad. Al filtrar una máscara booleana de la clase considerada, el filtro de media produce un valor de 1 cuando se encuentra por completo dentro de la clase existente, y un valor de 0 cuando está completamente fuera de la misma. Sin embargo, cuando cruza el borde, este filtro produce valores que rápidamente se transforman de 1 a 0. Este resultado luego es multiplicado por la imagen de adecuación para esa clase, y así progresivamente pondera en forma negativa las adecuaciones a medida que uno se aleja de las instancias existentes de esa clase. Observe que es posible aplicar un filtro diferente al especificar un archivo de filtro alternativo (.fil). Además, tenga en cuenta que las máscaras de clase son definidas en cada paso para incorporar nuevas áreas de crecimiento.

El resultado neto de este proceso iterativo es que los cambios de la cobertura terrestre se desarrollan como un proceso de crecimiento en las áreas de adecuación alta próximas a las áreas existentes. El CA\_MARKOV es intensivo en el uso de la computadora – una ejecución típica puede incluir miles de operaciones SIG. Entonces, Ud. debe comenzar la ejecución de este módulo cuando no necesite su computadora para otra actividad durante 15 ó 30 minutos.

## Validación del Modelo

Un paso importante en el desarrollo de cualquier modelo de cambios predecibles es la validación. Usualmente, uno mide el entendimiento que uno tiene del proceso y el poder del modelo haciendo que éste prevea algún período de tiempo del cuál ya se conocen las condiciones de la cobertura terrestre. Esto luego se usa como una prueba para la validación. IDRISI brinda un par de módulos para asistir el proceso de validación.

El primero se denomina VALIDATE, y provee un análisis comparativo sobre la base del Índice de Acuerdo Kappa. Éste es esencialmente una declaración de exactitud proporcional, ajustada para el acuerdo de oportunidad. Sin embargo, a diferencia de la estadística Kappa tradicional, VALIDATE divide la validación en varios componentes, cada uno con una forma especial de Kappa o de una estadística asociada (basado en el trabajo de Pontius (2000)):

- Kappa para ninguna información = K<sub>no</sub>
- Kappa para la ubicación = K<sub>location</sub>
- Kappa para la cantidad = K<sub>quantity</sub>
- Kappa estándar = K<sub>standard</sub>
- Valor de Información Perfecta de la Ubicación = VPIL
- Valor de Información Perfecta de la Cantidad = VPIQ

Con semejante análisis, por ejemplo, es posible determinar el éxito con el cual uno es capaz de especificar la ubicación del cambio versus la cantidad de cambio.

El otro procedimiento de validación es el ROC (Característica Operativa Relativa). Se utiliza para comparar cualquier declaración acerca de la probabilidad de una ocurrencia sobre un mapa booleano que muestra las ocurrencias verdaderas.

Éste puede ser útil, por ejemplo, para validar las modificaciones hechas a la producción de mapas de probabilidad condicional del MARKOV. Observe que el LOGISTICREG incorpora el ROC directamente en su producción.

## Referencias

Pontius Jr., R.G., 2000. Quantification error versus location error in comparison of categorical maps. *Photogrammetric Engineering and Remote Sensing*. 66(8) pp. 1011-1016.

# CAPÍTULO 21 - Modelador de Cambios en el Terreno para la Sustentabilidad Ecológica

## Introducción

El Modelador de Cambios en el Terreno (LCM) para el Sustento Ecológico es un software integrado dentro de IDRISI orientado al constante problema de conversión acelerada del terreno y a las necesidades analíticas bien específicas de la conservación de la biodiversidad. Clark Labs trabajó junto a Conservación Internacional durante un período de varios años para desarrollar este conjunto de herramientas pensadas para ser utilizadas en una variedad de escenarios y contextos de cambios en el terreno. En LCM, las herramientas para la evaluación y la predicción de los cambios en la corteza terrestre y sus consecuencias están organizadas en torno a grandes áreas de tareas: análisis de cambios, predicción de cambios, evaluación del hábitat y su impacto sobre la biodiversidad e intervenciones de planeamiento. Además, hay una función en LCM para ayudar en proyectos dirigidos a la Reducción de Emisiones de la Deforestación y la Degradación de los Bosques (REDD). La función REDD utiliza los escenarios de cambios en el terreno producidos por LCM para evaluar futuros escenarios de emisiones.

LCM es una aplicación vertical dentro de IDRISI. Sin embargo, a diferencia de IDRISI que puede caracterizarse como una aplicación horizontal y es un producto software diseñado para cumplir muchas funciones, una aplicación vertical está orientada a una sola función específica. El Modelador de Tendencias Terrestres es otra aplicación vertical dentro de IDRISI.

## Organización de LCM

La interfaz del Modelador de Cambios en el Terreno está organizada en torno a un grupo de seis tareas principales:


- Análisis de Cambios – Analiza cambios pasados en la corteza terrestre.
- Potenciales de Transición – Modela el potencial para transiciones en el terreno.
- Predicción de Cambios – Predice el curso de los cambios en el futuro.
- Consecuencias – Evalúa las consecuencias para la biodiversidad.
- Planeamiento – Evalúa las intervenciones de planeamiento para mantener el sustento ecológico.
- Proyecto REDD – Calcula la emisiones GHG de los proyectos REDD.
- Harmonizar – Formatea los mapas de la superficie terrestre para su posterior uso con el Modelador de Cambios en el Terreno (esta pestaña solo se activa cuando los mapas de la superficie terrestre están formateados incorrectamente).

La pestaña Harmonize (Harmonizar) no se muestra por defecto y solo aparecerá si los mapas de la superficie terrestre utilizados en el análisis están formateados incorrectamente para su uso en LCM. Los mapas de la superficie terrestre utilizados por LCM deben ser formateados para cumplir con las siguientes condiciones:

1. Los textos en ambos mapas son los mismos.
2. Las categorías en ambos mapas son las mismas y son secuenciales.
3. Los fondos en ambos mapas son los mismos y tienen un valor de cero.
4. Las dimensiones espaciales, incluyendo la resolución y las coordenadas, son las mismas.

Si el mapa no cumple con alguna de estas condiciones, la pestaña Harmonize se abrirá y permitirá al usuario realizar cambios en los mapas de entrada de la superficie terrestre. Todo error debe ser corregido antes de continuar con el análisis de cambios en LCM.

Dentro de cada pestaña, aparecen grupos de tareas y fases analíticas en forma de paneles desplegados. Pueden abrirse tantos paneles desplegados como se desee (se presentan con este formato para ajustarse a las distintas resoluciones de pantalla).



Las primeras tres pestañas de las seis que posee LCM están pensadas para el análisis integrado de los cambios en la superficie terrestre y su proyección en el futuro. Como resultado, el acceso a casi todos los paneles de estas pestañas requiere un mínimo de parámetros de proyecto ubicados en el primer panel de la primera pestaña.

Tenga en cuenta que los paneles de las tres primeras pestañas están generalmente organizados en torno a un grupo secuencial de operaciones que deben llevarse a cabo una tras otra.

## El Proceso de Predicción de Cambios en LCM

La predicción de cambios terrestres en LCM es un proceso empírico que avanza paso a paso desde el 1) Análisis de Cambios, al 2) Modelador del Potencial de Transición, a la 3) Predicción de Cambios. Se basa en los cambios históricos de los mapas de superficies terrestres del momento 1 al momento 2 para proyectar futuros escenarios. Al final del capítulo, hay dos diagramas de flujo que brindan una visualización del proceso.

### Análisis de Cambios

En el Análisis de Cambios, se evalúa el cambio entre el momento 1 y el momento 2 de los dos mapas de superficie terrestre. Los cambios identificados son transiciones de un estado de la superficie terrestre a otro. Es probable que con muchas clases de superficies terrestres, la combinación potencial de transiciones sea muy grande. Lo importante es identificar las transiciones dominantes que puedan agruparse y modelarse en submodelos determinados. Cada grupo o submodelo de transiciones puede modelarse separadamente, pero en definitiva cada submodelo será combinado con todos los submodelos en la predicción final de cambios.

### Modelador del Potencial de Transición

El segundo paso en el proceso de Predicción de Cambios es el Modelador del Potencial de Transición, donde identificamos el potencial del terreno para la transición. En esta etapa, crearemos mapas de potencial de transición que son básicamente mapas de adecuación para cada transición. En LCM, se organiza una serie de mapas de potencial de transición dentro del marco de un submodelo de transición evaluado empíricamente y que posee las mismas variables determinantes de fondo. Un submodelo de transición puede consistir en una sola transición de la superficie terrestre o en un grupo de transiciones que comparten las mismas variables determinantes de fondo. Estas variables determinantes son utilizadas para modelar el proceso de cambios históricos. Por ejemplo, si usted está modelando la deforestación causada por la agricultura, las variables determinantes a considerar son las pendientes, la cercanía a carreteras o la cercanía a áreas previamente deforestadas. Las transiciones son modeladas con alguna de las siguientes funciones: una red neural de perceptrones multicapas (MLP), la regresión logística o bien con una herramienta de aprendizaje basada en instancias de similitud medida (SimWeight). Una vez calibrado, el modelo es utilizado para predecir escenarios futuros.

### Predicción de Cambios

El tercer y último paso en el Análisis de Cambios es la Predicción de Cambios. Utilizando los índices históricos de cambios y el modelo del potencial de transición, LCM puede predecir un escenario futuro para una determinada fecha futura. En su forma más simple, el modelo determinará cómo las variables influyen en los cambios futuros, cuántos cambios sucedieron entre el momento 1 y el momento 2, y luego calculará una cantidad relativa de transición a la fecha futura. Para hacer que el modelo sea más fuerte, el Modelador de Cambios en el Terreno permite la incorporación de restricciones e incentivos tales como los mapas de zonificación, y la incorporación de cambios en la infraestructura planeada tales como nuevas carreteras o mejoras en la superficie terrestre. Las variables determinantes también pueden ser dinámicas por naturaleza, de manera que se pueden recalcular en intervalos regulares permitiendo reingresar el modelo. Por ejemplo, una de las variables determinantes puede ser la distancia desde las áreas previamente deforestadas. Esta variable puede ser recalculada en intervalos regulares como transiciones de la superficie terrestre de bosque a terreno para la agricultura.

### La pestaña de Análisis de Cambios (Change Analysis)

El primer paso en el proceso de la predicción de cambios es el Análisis de Cambios. La pestaña del Análisis de Cambios brinda un grupo de herramientas para lograr una rápida evaluación de los cambios, lo cual nos permite realizar evaluaciones con un solo click acerca de las pérdidas y las ganancias, el cambio neto, las transiciones de persistencia y específicas, ambas en forma de mapas y de gráficos. La pestaña del Análisis de Cambios consiste en cuatro paneles: Parámetros de Proyecto, Análisis de Cambios, Mapas de Cambios y Tendencia Espacial del Cambio.

#### Panel de Parámetros de Proyecto (Project Parameters)

Este panel permite especificar los archivos esenciales asociados con el análisis de cambios en la superficie terrestre

de un área de estudio específica. Algunos aspectos de LCM puede usarse sin especificar estos archivos, principalmente las herramientas del modelador de especies y de la biodiversidad en la pestaña Implications (Consecuencias). Sin embargo, estos archivos se necesitan para la mayoría de los elementos de LCM.

Para los análisis de cambios y de predicción, el requisito mínimo es la especificación de dos mapas de la superficie terrestre que puedan usarse como base para entender la naturaleza de los cambios en la región estudiada y como medio para establecer muestras de transiciones que deban ser modeladas. Las entradas opcionales incluyen un modelo de elevación y una capa de carreteras de base utilizadas en el desarrollo dinámico de carreteras.

### Panel de Análisis de Cambios (Change Analysis)

El Panel del Análisis de Cambios brinda una rápida evaluación cuantitativa de los cambios a través de gráficos de ganancias y pérdidas por categoría de superficie terrestre. Una segunda opción, el cambio neto, muestra el resultado de tomar las áreas de superficies terrestres anteriores, agregar las ganancias y luego restar las pérdidas. La tercera opción es examinar las contribuciones a los cambios experimentados por una sola categoría de superficie terrestre.

### Panel de Mapas de Cambios (Change Maps)

Este panel brinda la habilidad para crear una variedad de mapas de cambios. Existen opciones para los cambios de mapas, persistencia, ganancias y pérdidas por categoría de superficie terrestre y transiciones o intercambios de mapas por categoría.

### Panel de Tendencia Espacial del Cambio (*Spatial Trend of Change*)

En aquellos paisajes dominados por la intervención humana, los patrones de cambios pueden ser complejos y, por lo tanto, muy difíciles de decifrar. Para facilitar la interpretación en estos contextos, IDRISI ofrece una herramienta para el análisis de la tendencia espacial. Esta es la superficie de tendencia polinómica que mejor se ajusta al patrón de cambios. El trabajo analítico realizado por esta opción se logra gracias al módulo TREND. Las tendencias pueden calcularse hasta el 9<sup>no</sup> orden.

### La pestaña de Potenciales de Transición (Transition Potentials)

La pestaña de Potenciales de Transición agrupa las transiciones entre dos mapas de superficie terrestre en un grupo de submodelos, donde a su vez cada submodelo es identificado con un grupo de variables determinantes o explicativas. De esto se deriva un mapa de potencial de transición para cada transición, el cual es una expresión del potencial de tiempo específico para el cambio. Esta pestaña ofrece funciones para transformar las variables determinantes y para explorar la fuerza potencial de cada una de las variables explicativas. Las variables pueden ser agregadas al modelo como componentes tanto estáticos como dinámicos. Las variables estáticas expresan aspectos de adecuación básica para la transición considerada y no cambian con el tiempo. Las variables dinámicas son determinantes dependientes del tiempo tales como la proximidad a zonas urbanas o infraestructuras, y son recalculadas en el tiempo durante el curso de una predicción.

Una vez que las variables del modelo han sido seleccionadas, cada submodelo de transición es modelado con uno de los tres tipos de modelos: 1) regresión logística, 2) red neural de perceptrones multicapas (MLP) o 3) procedimiento SimWeight, el cual está basado en un algoritmo modificado del aprendizaje de la herramienta vecino más cercano a K. El procedimiento SimWeight aparece para emitir resultados similares a los del procedimiento MLP, pero con parámetros mínimos. Además, SimWeight es más fácil de completar. Sin embargo, la red neural MLP ha sido ampliamente mejorada para ofrecer un modo automático que no necesita la intervención del usuario. Luego de una evaluación detallada de las herramientas de modelado empírico (tales como Pesos de la Evidencia/Weights-of-Evidence, Probabilidades Empíricas/Empirical Probabilities, Posibilidades Empíricas/Empirical Likelihoods, etc.), se descubrió que estos tres enfoques brindan las capacidades más fuertes, particularmente SimWeight y MLP<sup>85</sup>. El resultado con todos los tipos de modelos es un mapa del potencial de transición para cada transición, expresión del potencial de tiempo específico para el cambio.

Por defecto, en LCM cada transición se considera como un submodelo separado; sin embargo, las transiciones múltiples pueden ser agrupadas en un solo submodelo si se considera que todas son producto de las mismas fuerzas impulsoras subyacentes. No obstante, solo MLP puede ser usado para modelar las transiciones múltiples en un submodelo.

---

<sup>85</sup> Eastman, J. R., L. Solorzano y M. Van Fossen. "Transition Potential Modeling for Land-Cover Change" (Modelador del Potencial de Transición para Cambios en la Superficie Terrestre). En SIG, Análisis y Modelador Espacial, editado por David J. Maguire, Michael Batty y Michael F. Goodchild, 357-385. Redlands, California: ESRI Press, 2005.

## Submodelos de Transición: Panel de Estado (Status)

El Panel de Estado de los Submodelos de Transición incluye todas las transiciones que existen entre los dos mapas de superficie terrestre. Las transiciones pueden ser filtradas utilizando un umbral de área y luego pueden ser asignadas a submodelos específicos. Las transiciones solo deben ser agrupadas si se sabe que las fuerzas impulsoras subyacentes del cambio son las mismas. Generalmente, a medida que aumenta el número de transiciones agrupadas en un submodelo, la tarea para MLP es cada vez más difícil de resolver. Esto puede calcularse fácilmente a partir del informe de precisión de la validación que brinda MLP.

## Panel de Utilidad para la Transformación de Variables (Variable Transformation Utility Panel)

El Panel de *Utilidad para la Transformación de Variables* es opcional y provee una selección de transformaciones opcionales usadas comúnmente. Estas transformaciones incluyen: posibilidad de evidencia/evidence likelihood, logaritmo natural/natural log (ln), exponencial/exponential (e), logística/logit, raíz cuadrada/square root y fuerza/power. Estas son particularmente fundamentales si se elige la opción de modelado por Regresión Logística/Logistic Regression ya que ésta exige que las variables estén linealmente relacionadas con el potencial para la transición. La opción MLP no requiere que las variables estén linealmente relacionadas, pero la transformación a veces puede facilitar la resolución en casos de falta de linealidad fuerte y arrojar así una precisión mayor. Generalmente, las transformaciones son evidentes; sin embargo, hay dos que requieren mención especial.

1. La transformación del logaritmo natural es efectiva para brindar linealidad a las variables de deterioro de la distancia (ej.: proximidad a las carreteras)

2. La transformación de *posibilidad de evidencia* es un medio muy efectivo para incorporar variables categóricas al análisis. Para todos los tipos de modelos, regresión logística, MLP y SimWeight, las variables deben ser convertidas en un grupo de variables Booleanas (falsas) o bien transformadas utilizando la opción de transformación de *posibilidad de evidencia* (muy recomendada).

La transformación de *Posibilidad de Evidencia* necesita dos entradas:

- Un mapa Booleano de áreas que han experimentado la transición modelada (éste puede crearse fácilmente desde la pestaña Análisis de Cambios/Change Analysis)
- Una variable categórica o una continua que ha sido descartada a distintas clases (como con el módulo STRETCH).

El procedimiento observa la frecuencia relativa de los píxeles pertenecientes a las diferentes categorías de esa variable dentro de las áreas de cambio. En efecto, formula la pregunta de cada categoría de la variable: “¿Cuán posible es tener un valor como éste si tuviese un área que experimentase cambios?”

## Panel de Prueba y Selección del Sitio y Variables Determinantes (Test and Selection of Site and Driver Variables)

Éste es un panel opcional que ofrece una prueba rápida de la fuerza explicativa potencial de una variable. Se pueden probar tanto variables cuantitativas como cualitativas. Sin embargo, las variables cualitativas deben ser desarticuladas en un grupo de capas Booleanas separadas, o bien transformadas con la herramienta de transformación de *Posibilidad de Evidencia* antes de ser usadas.

El *procedimiento de prueba de las variables* explicativas está basado en un análisis de tabla de contingencias. Para las variables cualitativas, éste usa las categorías nativas de la variable para probar la asociación con la distribución de superficies terrestres en el posterior mapa de superficies terrestres. Las variables cuantitativas son *descartadas* a 256 categorías para poder realizar esta prueba. Ésta es una herramienta de pesca rápida pero poco precisa. La medida cuantitativa de asociación utilizada es la V de Cramer. Una V de Cramer alta indica que el valor explicativo *potencial* de la variable es bueno, aunque no garantiza un desempeño enérgico ya que no puede responder a los requerimientos matemáticos del enfoque de modelado utilizado ni a la complejidad de la relación. No obstante, es un buen indicador de que una variable pueda descartarse si la V de Cramer es baja. El valor  $p$  expresa la probabilidad de que la V de Cramer no sea tan diferente de 0. Tenga en cuenta que esto supone que todos los píxeles son elegidos independientemente y no dependen espacialmente de sus valores.

Entonces, un valor bajo de  $p$  no es buen indicador del valor de una variable, pero un valor alto es una señal segura de que puede ser rechazada. En general, hemos descubierto que las variables que tienen una V de Cramer de 0,15 o más son útiles, mientras que aquellas con valores de 0,4 o más son buenas.



## Panel de Estructura del Submodelo de Transición (Transition Sub-Model Structure)

El Panel de la Estructura del Submodelo de Transición ofrece una tabla para especificar las variables explicativas a ser evaluadas. Para cada submodelo, se especifica una lista de variables explicativas que serán modeladas en el siguiente panel. Cada una de estas variables puede ser estática o dinámica. Las variables estáticas son variables de sitio que no cambian con el tiempo, tales como pendiente, elemento, etc. Las variables dinámicas son aquellas que sí cambian con el tiempo, tales como la proximidad a los desarrollos urbanos o la proximidad a las carreteras (teniendo en cuenta el crecimiento dinámico de las carreteras).

Si una variable es dinámica, existe la opción para identificar si es dinámica basada en una categoría de superficie terrestre (como la proximidad a áreas urbanas) o basada en una categoría de carreteras (como la proximidad a carreteras secundarias). También existe la opción para especificar si la operación dinámica es un cálculo de distancia o si utilizar un archivo Macro de IDRISI. El cálculo de distancia es la opción más común que calculará la distancia desde las categorías designadas de superficie terrestre o de carreteras. La opción MACRO deja infinitas posibilidades abiertas.

Cuando una variable es designada como dinámica y el tipo de capa de base es seleccionado como carreteras o uso del terreno, se abrirá un cuadro de diálogo para especificar la categoría de superficie terrestre relevante o las categorías de carreteras desde las cuales debe calcularse la distancia en la etapa de predicción de cambios. Si una capa de carreteras no fue especificada en la pestaña LCM Project Parameters (Parámetros de Proyecto LCM), usted podrá especificarla en el diálogo que luego actualizará el campo de la capa de carreteras de base en la pestaña LCM Project Parameters.

## Panel de Activación del Submodelo de Transición (Run Transition Sub-Model)

El panel de Activación del Submodelo de Transición es donde se implementa el verdadero modelador de los submodelos de transición. El submodelo específico que se implementará es aquel especificado en el cuadro de diálogo desplegable Sub-Model to be Evaluated (Submodelo a Evaluar) dentro del panel Transition Sub-Models: Status.

Se ofrecen tres metodologías para el proceso modelador: un perceptrón multicapas (MLP), SimWeight y regresión logística. Generalmente, recomendamos mucho el uso de MLP y SimWeight. En cualquiera de los casos, cuando se hace click en el botón Run Sub-Model (Activar Submodelo), el proyecto LCM extrae muestras de los dos mapas de superficie terrestre. Estas muestras son las áreas que experimentaron las transiciones modeladas y también las áreas que fueron elegidas para el cambio pero no cambiaron. Para cada opción de modelado, se deben establecer ciertos parámetros.

### SimWeight

SimWeight solo puede modelar una transición por vez. Se trata de un algoritmo del Aprendizaje de la Herramienta basada en Instancias de Similitud Medida (Similarity-Weighted Instance-based Machine Learning). Utiliza una variable mínimamente modificada del procedimiento “vecino más cercano a K” (K-nearest neighbor<sup>86</sup>). Hay dos parámetros primarios que deben ser especificados: el tamaño de la muestra y K. El tamaño de la muestra solo debe ser lo suficientemente grande para ser representativo. Usualmente, un tamaño de muestra de 1000-2000 píxeles se desempeña correctamente (la mitad de éstos será utilizada para pruebas). El parámetro K gobierna el grado de generalidad de la solución. Una configuración demasiado baja del valor K resultará en una práctica excesiva. Por otra parte, una configuración demasiado alta se reflejará en una generalización excesiva. Recomendamos comenzar con una K de 1/10th del tamaño de la muestra aproximadamente. La práctica excesiva se verá como artefactos espaciales, en cuyo caso se recomienda aumentar la K y reactivar el modelo hasta lograr un resultado liso. La práctica excesiva en los potenciales de transición más bajos generalmente no es importante. La preocupación más significativa es la práctica excesiva en los potenciales de transición más altos.

SimWeight utiliza la mitad de los píxeles de la muestra para validación. El índice de éxito mide los potenciales de transición promedio entre los píxeles de validación que en realidad experimentaron la transición. A su vez, el índice de falsa alarma mide los potenciales de transición promedio entre los píxeles que han sido elegidos para el cambio pero no cambiaron. La diferencia entre estos dos es el Puntaje de Habilidades Peirce (Peirce Skill Score).

---

<sup>86</sup> Sangermano, F., Eastman, J.R., Zhu, H., (2010). Similarity weighted instance based learning for the generation of transition potentials in land change modeling (Aprendizaje basado en instancias de similitud medida para la generación de potenciales de transición en el modelado de cambios en el terreno). Transactions in GIS (Transacciones en SIG), 14(5), 569-580.

El cálculo de las medidas de relevancia es indicativo de la importancia de esa variable en el modelo. La relevancia se calcula como:

$$1 - \left( \frac{\sigma \text{ dentro del área de cambio}}{\sigma \text{ de toda la imagen}} \right)$$

## Perceptrón Multicapas (Multi-Layer Perceptron)

La opción MLP puede modelar múltiples transiciones al mismo tiempo. El diálogo MLP en LCM ha sido modificado a partir del módulo MLP ya existente en IDRISI usado para la clasificación de imágenes. Al principio, el diálogo para la red neural de Perceptrones Multicapas puede parecer intimidante, sin embargo la mayoría de los parámetros presentados no necesitan ser modificados (ni siquiera entendidos) para poder usar productivamente esta poderosa técnica.

Ni bien es iniciado por LCM, el Perceptrón Multicapas empieza a practicar con las muestras otorgadas de píxeles que han experimentado o no la transición modelada. En esta instancia, MLP está funcionando en modo *automático* por el cual toma sus propias decisiones acerca de los parámetros a utilizar y cómo deberían ser cambiados para modelar mejor los datos. El modo automático monitorea y modifica el índice de aprendizaje inicial y final de un procedimiento de aprendizaje dinámico. El procedimiento de aprendizaje dinámico comienza con un índice de aprendizaje inicial y lo reduce progresivamente a lo largo de las repeticiones hasta alcanzar el índice de aprendizaje final cuando se llega al máximo número de repeticiones. Si se detectan oscilaciones significativas en el error RSM luego de las 100 primeras repeticiones, los índices de aprendizaje (inicial y final) se reducen a la mitad y el proceso comienza nuevamente.

Todos los demás parámetros de MLP son usados por LCM en sus valores normales por defecto. Sin embargo, LCM sí aplica modificaciones especiales a la información de salida. Al estar modelando transiciones específicas, LCM oculta de los potenciales de transición todos los casos de cualquier transición específica que no coinciden con el caso *from* (desde). Por ejemplo, si la transición modelada es de bosque a agricultura, los valores solo existirán en los píxeles que eran bosque al principio.

En la mayoría de los casos, se lo puede activar en este modo hasta que completa su práctica. No obstante, usted tiene libertad para detener la operación de práctica, modificar los parámetros y comenzar la práctica nuevamente. Una vez completado el proceso de práctica, se pueden crear los mapas de potenciales de transición. Para información detallada sobre los parámetros de MLP, lea la ayuda online para MLP (Help System).

## Regression Logística (Logistic Regression)

En contraste con MLP, la regresión logística solo puede modelar una transición por vez. Por lo tanto, se inicia en un modo que está listo para modelar la transición específica indicada en el cuadro de diálogo desplegable del panel Transition Sub-Models: Status. Aunque depende del tamaño de los datos de entrada, se recomienda activar la regresión logística con una proporción de muestreo por defecto del 10%, lo cual reducirá el tiempo de procesamiento. Este modelo lleva a cabo la regresión logística binomial y la predicción utilizando el método de Probabilidad Máxima (Maximum Likelihood). Para una explicación detallada de los parámetros del módulo regresión logística, lea la ayuda online Help System.

## Ficha de Predicción de Cambios (Change Prediction Tab)

La ficha Change Prediction (Predicción de Cambios) brinda los controles para realizar un proceso de predicción dinámica de cambios en la cubierta del terreno. Luego de especificar la fecha final, la cantidad de cambio en cada transición puede ser modelada por medio del análisis Markov Chain (Cadena de Markov) o bien especificando la matriz de probabilidad de transición desde un modelo externo (ej.: econométrico). Hay dos modelos básicos de cambios: un modelo de predicción dura y un modelo de predicción blanda. El modelo de predicción dura está basado en un modelo de asignación competitiva de terreno similar a un proceso de decisión multi-objetivo. La predicción blanda produce un mapa de vulnerabilidad para cambiar por el grupo de transiciones seleccionado. Por lo general, preferimos los resultados de la predicción blanda para evaluar el hábitat y la biodiversidad. La predicción dura produce un solo resultado, mientras que la predicción blanda es una evaluación exhaustiva del potencial de cambios.

Al configurar el análisis de la predicción de cambios, el usuario puede especificar el número de etapas de revaloración dinámica durante las cuales se actualizan las variables dinámicas. Ésto además incluye el crecimiento dinámico opcional (intensificación) de la red de carreteras. En cada etapa, el sistema también verifica la presencia de

intervenciones de planificación (ver abajo), incluyendo los incentivos y restricciones y las mejoras en infraestructura más importantes.

La pestaña de Predicción de Cambios (Change Prediction) usa información de otras varias pestañas. Es de suma importancia que todas las transiciones incluidas en la pestaña de Potenciales de Transición (Transition Potentials) hayan sido modeladas previamente con MLP, SimWeight o regresión logística. Hay opciones para incluir cambios infraestructurales o incentivos y restricciones especificados en la pestaña de Planificación (Planning).

### Panel Modelador de la Demanda de Cambios (Change Demand Modeling)

El procedimiento por defecto para determinar la cantidad de cambio que ocurrirá en algún momento en el futuro se realiza por medio de una Cadena Markov. Un proceso Markoviano es uno en el cual el estado de un sistema puede determinarse con el conocimiento de su estado anterior y la probabilidad de transición de cada uno de los estados a otro estado. Para determinar esto, el LCM se conecta con el módulo MARKOV de IDRISI cuando se ejecuta una predicción. Al utilizar el primer y segundo mapa de cubierta de terreno junto con la fecha especificada, MARKOV calcula exactamente cuánto terreno se espera que realice la transición desde la última fecha a la fecha de predicción basándose en una proyección de los potenciales de transición en el futuro. Observe que ésta no es una simple extrapolación lineal ya que los potenciales de transición cambian con el tiempo a medida que varias transiciones en efecto alcanzan un estado de equilibrio.

Las probabilidades de transición Markov por defecto son calculadas al ingresar la fecha de predicción final. La matriz Markov resultante puede ser visualizada y editada. O bien, usted puede especificar un archivo de probabilidad de transición de alguna otra herramienta de proyección, como por ejemplo el modelo econométrico.

### Panel del Desarrollo Dinámico de Carreteras (Dynamic Road Development)

Este panel establece los parámetros para el desarrollo dinámico de carreteras. Es un procedimiento que intenta predecir cómo se desarrollarán las carreteras en el futuro<sup>87</sup>. Se reconocen tres niveles de carreteras: primaria, secundaria y terciaria; las cuales deben estar codificadas con valores en números enteros: 1, 2 y 3 respectivamente. Las carreteras primarias solo pueden crecer por medio de la prolongación de sus extremos (si estos extremos se encuentran dentro del mapa). Las carreteras secundarias pueden desarrollarse como nuevas ramificaciones de las carreteras primarias, y además pueden prolongarse. De igual forma, las carreteras terciarias pueden desarrollarse como nuevas ramificaciones de las secundarias, y también pueden prolongarse. Las siguientes opciones controlan los patrones de desarrollo y crecimiento de nuevos extremos y caminos:

#### Parámetros para el Desarrollo de Carreteras (Road Growth Parameters)

Los parámetros esenciales para el control del desarrollo dinámico de carreteras son la distancia entre carreteras (*road spacing*) y la longitud de carreteras (*road length*). El primer parámetro indica la frecuencia con la que se generan las carreteras a lo largo de una ruta de superior categoría. El segundo indica la longitud máxima que una clase de carretera alcanzará en cada etapa dinámica. La longitud real de cualquier segmento nuevo se encontrará dentro de ese rango.

#### Modo para el Desarrollo de Extremos (Mode of End-Point Generation)

Dentro de los límites de los parámetros de control, los nuevos extremos de las carreteras pueden desarrollarse aleatoriamente o bien por medio de un procedimiento que busca la ubicación del potencial de transición más alto pero con una perturbación estocástica. En lugar de elegir la ubicación con el potencial de transición absoluto más alto dentro del parámetro de crecimiento de longitud, se agrega una pequeña perturbación aleatoria a los potenciales de transición de forma tal que hay una gran posibilidad de que elija una ubicación muy similar al potencial de transición más alto y, por el contrario, hay cada vez menos probabilidad de que elija una ubicación bastante diferente.

La utilización de la opción del potencial de transición estocástico más alto solo permite la selección de aquellas transiciones que son importantes para el crecimiento de carreteras. Por ejemplo, un modelo puede incluir

---

<sup>87</sup> El desarrollo dinámico de caminos en IDRISI fue inspirado por el trabajo pionero del equipo DINAMICA. Ver Soares-Filho, B.S.; Assunção, R.M.; Pantuzzo, A. Modeling the spatial transition probabilities of landscape in an Amazonian colonization frontier. *BioScience*, v. 51, p.1039-1046, 2001.

Veá también Jiang, Ziyang. "The Road Extension Model in the Land Change Modeler for Ecological Sustainability of IDRISI." 15th ACM International Symposium on Advances in Geographic Information Systems, Nov. 7-9, 2007, Seattle, WA.

transiciones relacionadas con una disminución tanto en agricultura como en urbanización. Evidentemente, una disminución en la agricultura no representa un buen panorama para el crecimiento de carreteras.

### Modo para el Desarrollo de Caminos (Mode of Route Generation)

Una vez que se ha creado un nuevo extremo para una carretera, existen dos opciones para seleccionar el camino que conecte esa ubicación con la red de carreteras existente. La opción predeterminada es el camino con la mínima pendiente (minimum gradient route). Este camino es un balance entre tratar de lograr un camino corto y la necesidad de evitar pendientes pronunciadas en la mayor medida posible. Por otra parte, el camino con el potencial de

transición más alto compensa la necesidad de un camino corto con el deseo de unir tantas áreas de potencial de transición alto como sea posible (suponiendo que estas áreas tendrán una alta probabilidad de necesitar una conexión de carreteras en el futuro).

Usar la opción del camino con el potencial de transición más alto solo permite la selección de aquellas transiciones que son importantes para el crecimiento de carreteras. Éstas son las mismas transiciones importantes para el desarrollo de los extremos (ver más arriba).

### Factor de Omisión (Skip Factor)

En nuestra experiencia hemos descubierto que a veces es más eficiente no construir carreteras en cada etapa, sino que es mejor construirlas luego de varias etapas. En conclusión, hay un parámetro del factor de omisión para establecer etapas en la construcción de carreteras.

### Panel de la Distribución de Cambios (Change Allocation)

Este Panel de Distribución de Cambios establece los parámetros e inicia el verdadero proceso de predicción. El proceso se basa en los mapas de potenciales de transición desarrollados en el panel de Potenciales de Transición (Transition Potentials) y la fecha de predicción es establecida en el panel Modelador de la Demanda de Cambios (Change Demand Modeling). Los siguientes parámetros pueden usarse para predecir cambios en la superficie terrestre:

### Etapas de Recálculo (Recalculation Stages)

Esta opción controla qué cantidad del total de los cambios debe ser distribuida a lo largo del proceso de predicción desde la última fecha de superficie terrestre hasta la fecha de predicción especificada. Por defecto, una etapa de recálculo de 1 asignará la totalidad de los cambios a la fecha de predicción. Al aumentar las etapas de recálculo, esa cantidad total de cambios será dividida finalmente en cada etapa durante el proceso de distribución. Por ejemplo, si usted distribuye 1000 hectáreas en un período de 10 años para predecir desde el año 2011 al 2020, y establece las etapas de recálculo en 2; el proceso asignará la mitad de los cambios al año 5 (2015) y la otra mitad al año 10 (2020).

La opción etapas de recálculo también establece la frecuencia con la que se recalculan los elementos dinámicos. Estos elementos incluyen: variables dinámicas, construcción dinámica de carreteras, cambios de infraestructura e incentivos y restricciones. Para cada uno de estos elementos, la cantidad total de cambios es asignada al número de etapas de recálculo de forma lineal, pero los elementos dinámicos son usados para alterar la ubicación de esta cantidad en cada etapa.

El uso de las variables dinámicas se establece en el panel Estructura del Submodelo de Transición (Transition Sub-Model Structure) de la pestaña Potenciales de Transición (Transition Potentials). Una variable dinámica cambia sus características con el tiempo. Por ejemplo, una de las variables asociadas con una transición específica puede ser la distancia desde áreas deforestadas. Con el paso del tiempo, el tamaño de estas áreas deforestadas aumentará y, por consiguiente, cambiará la variable de la distancia. Todas las variables explicativas establecidas como dinámicas son recalculadas en cada etapa.

La construcción dinámica de carreteras se lleva a cabo (a menos que se haya establecido un factor de omisión) por medio del panel de Desarrollo Dinámico de Carreteras (Dynamic Road Development). Este proceso es un modelador predictivo del desarrollo y crecimiento de las carreteras en el tiempo.

Los cambios en la infraestructura son revisados e incorporados según la necesidad. Éstos se especifican en la pestaña Planeamiento (Planning). Por ejemplo, los mismos podrían incluir nuevas carreteras conocidas para ser desarrolladas en períodos de tiempo específicos en el futuro.

Los incentivos y las restricciones son aplicados a cada mapa de potenciales de transición del modelo. En cada etapa

de recálculo, el mapa de potenciales de transición asociado con cada transición es básicamente multiplicado por el mapa de incentivos y restricciones durante el proceso de predicción de cambios. Estos mapas de incentivos y restricciones son también especificados en la pestaña Planeamiento (Planning).

### Predicción Dura versus Blanda (Hard Versus Soft Prediction)

LCM ofrece dos modos para la predicción de cambios: duro y blando. Una predicción dura está comprometida con un escenario específico. El resultado es un mapa de la superficie terrestre con las mismas categorías que los datos de entrada. El procedimiento de predicción dura utilizado por LCM se basa en el módulo de IDRISI para la distribución multi-objetiva de terrenos (MOLA). IDRISI observa todas las transiciones y crea una lista de clases anfitrionas (dichas clases perderán una cantidad de terreno) y una lista de clases demandantes (estas clases adquirirán terrenos) para cada anfitrión. Las cantidades son determinadas a partir del módulo MARKOV. Entonces, se aplica una distribución multi-objetiva para asignar terrenos a todos los demandantes de una clase anfitriona. Los resultados de la reasignación de cada clase anfitriona son luego superpuestos para generar el resultado final. El módulo que lleva a cabo esta tarea es CHGALLOC, el cual es un módulo interno que no se encuentra en el sistema del menú. Durante su funcionamiento, éste informará el número de pases, el cual es idéntico al número de clases anfitrionas.

Por el contrario, los resultados blandos son un mapeo continuo de la vulnerabilidad al cambio. Éstos no indican qué es lo que va a cambiar, sino el grado en el que las áreas tienen las condiciones correctas para precipitar un cambio. Se trata simplemente de agrupar los potenciales de transición de todas las transiciones seleccionadas.

Cuando se crea la predicción blanda, existe la opción de seleccionar qué transiciones incluir en el perfil de la vulnerabilidad. Por defecto, todas las transiciones usadas para desarrollar el modelo de predicción son seleccionadas, en cuyo caso se modela la vulnerabilidad a cualquier tipo de cambio. Comúnmente, usted solo seleccionará ciertas transiciones para ser incluidas. Por ejemplo, si está interesado en los bosques, usted va a incluir todas las transiciones relacionadas con la pérdida de las superficies de bosques.

También existe la opción de establecer el tipo de agrupación para la predicción blanda. Esta predicción está basada en el estado actual (durante la predicción) de los potenciales de transición para cada una de las transiciones seleccionadas. Estos potenciales son luego agrupados con el propósito de producir los resultados blandos para cada etapa. Se brindan dos opciones de agrupación: OR *máxima* y *lógica*. La primera caracteriza a un píxel por la máxima probabilidad de transición que existe en esa ubicación para las transiciones incluidas. La segunda calcula la OR lógica de estos potenciales de transición. Esta última opción trata una ubicación como más vulnerable si es requerida por varias transiciones al mismo tiempo. Por ejemplo, si cierto píxel es evaluado con 0,6 como su potencial de transición a un tipo de superficie y con 0,7 a otro tipo de superficie, la opción OR máxima calculará su vulnerabilidad al cambio y su resultado será 0,7; mientras que la opción OR lógica la evaluará con un resultado de 0,88  $((A+B)-(A*B))$ . El usuario debe decidir cual es la opción más apropiada para el contexto de estudio en el que se lleva a cabo.

### Opciones de Visualización (Display Options)

LCM brinda varias opciones para la visualización de predicciones. Una de ellas muestra las imágenes de las etapas intermedias (a diferencia de mostrar solamente la predicción final). Esta opción debe usarse con cuidado ya que la memoria de Windows puede llenarse rápidamente y desestabilizar todo el sistema operativo. Este límite dependerá, en parte, de cuánta memoria RAM tenga su sistema.

Una segunda opción para la visualización es crear un archivo de video AVI. Este archivo puede verse con IDRISI Media Viewer que se encuentra en el menú Display. También puede reproducirse con programas como Microsoft Media Player e insertarse en presentaciones Microsoft PowerPoint. Para las secuencias largas, una velocidad de cuadros de 0,25 generalmente funciona bien; mientras que para secuencias más lentas es más apropiada una velocidad menor.

### Panel de Validación (Validation)

Este panel le permite determinar la calidad del mapa de predicción del uso del terreno en relación con el mapa real. Esto se logra gracias a una tabulación cruzada de 3 líneas entre el último mapa de superficie terrestre, el mapa de la predicción y el mapa de la realidad. Los datos ilustrarán la precisión de los resultados del modelo, donde:

A | B | B = Aciertos (verde) — El modelo predijo un cambio y éste ocurrió

A | A | B = Errores (rojo) — El modelo predijo una persistencia pero hubo un cambio

A | B | A = Falsa Alarma (amarillo) — El modelo predijo un cambio pero éste no ocurrió

## Pestaña de Repercusiones (Implications Tab)

Se ofrece una amplia gama de herramientas para evaluar el impacto de los cambios sobre el sustento ecológico, incluyendo aquellas para la evaluación de hábitats de determinadas especies, el análisis de cambios en el hábitat, el análisis de intervalos/brechas espaciales, el análisis de patrones de paisajes y el análisis de la biodiversidad.

### Panel de Evaluación del Hábitat (Habitat Assessment)

Este panel permite evaluar el estado del hábitat partiendo de una especie animal determinada<sup>88</sup>. La herramienta para la evaluación del hábitat se basa en cualquiera de los mapas existentes o predecidos de la superficie terrestre y en un mapa opcional de aptitud del hábitat para especies determinadas. Ésta desarrolla un mapa con cinco categorías: hábitat primario, hábitat secundario, corredor potencial primario, corredor potencial secundario e inadecuado. Los parámetros importantes que controlan este proceso incluyen: el tamaño del área del hábitat, las zonas de protección basadas en la sensibilidad a los humanos y la habilidad para cruzar los intervalos espaciales dentro del área del

hábitat y durante la dispersión. El mapa resultante puede usarse para estimar las poblaciones máximas y sirve como un recurso primario para el planeamiento de corredores. El mapa de aptitud del hábitat puede crearse con el panel de Aptitud del Hábitat / Distribución de las Especies (Habitat Suitability / Species Distribution).

Pueden ejecutarse cualquiera de estos tres análisis: evaluación del primer mapa de superficie terrestre, del último mapa de superficie terrestre o de la predicción actual. Se deben especificar los siguientes parámetros y términos:

### Hábitat y Corredor Potencial (Habitat and Potential Corridor)

El mapa de evaluación del hábitat producido por este análisis incluye cinco categorías para el estado del hábitat. Se detallan a continuación con una interpretación posible. Sin embargo, pueden interpretarse de cualquier forma que parezca apropiada para el estudio en consideración.

1. Hábitat Primario: este hábitat cubre todas las necesidades básicas para la vida referidas al tamaño del área del hábitat, acceso al forraje de verano e invierno, etc. Los demás factores, excepto el área mínima y el tamaño de la zona de protección requerida, son especificados por una aptitud mínima en un mapa de aptitud del hábitat.
2. Hábitat Secundario: incluye aquellas áreas que tienen los tipos de superficie de hábitat designados, pero no poseen uno o más requisitos para ser hábitat primario (como el área o el nivel de aptitud mínimo). Las zonas de hábitat secundario brindan áreas de forraje y refugios seguros para la dispersión de los animales cuando se mueven hacia nuevas áreas de hábitat primario.
3. Corredor Potencial Primario: éstas son áreas sin hábitat suficientemente seguras para ser atravesadas, por ejemplo, de noche.
4. Corredor Potencial Secundario: se sabe que estas áreas son atravesadas por las especies en consideración, pero constituyen tipos de superficie mucho más riesgosas.
5. Inadecuado: estas zonas no son adecuadas para hábitats ni corredores.

### Incluir como Hábitat Potencial (Include as Potential Habitat)

Cualquier tipo de superficie terrestre perteneciente a los mapas de entrada puede incluirse en el estudio y puede seleccionarse para aquellos tipos asociados con el hábitat de la especie en consideración.

### Distancia del Intervalo Espacial dentro del Área del Hábitat (Gap Distance Within Range)

Este parámetro se encarga de los intervalos dentro del área del hábitat de la especie en consideración. Las distancias de los intervalos no necesitan ser especificadas por los tipos de superficie terrestre incluidos como componentes del hábitat potencial.

### Distancia del Intervalo Espacial fuera del Área del Hábitat (Gap Distance Outside Range)

---

<sup>88</sup> El procedimiento de evaluación del hábitat aquí introducido fue inspirado por el trabajo de Bow Corridor Ecosystem Advisory Group (BCEAG) en el desarrollo de una estrategia de corredor para la Región Sur de Canmore en Alberta, Canadá. Para obtener más información, refiérase a [http://www.stratalink.com/corridors/wildlife\\_corridors\\_report.htm](http://www.stratalink.com/corridors/wildlife_corridors_report.htm).



Este parámetro se encarga de las zonas de intervalos que el animal es capaz de cruzar cuando se dispersa; y es importante para determinar qué áreas pueden servir como corredores potenciales. Además, establece eficazmente la longitud máxima del corredor.

### Área Central Mínima (Minimum Core Area)

La misma constituye, en el caso de un hábitat primario, el área mínima del hábitat de la especie considerada, sin incluir las zonas de protección periférica que pudieran existir (por ello el uso del término *central*). Para las zonas de hábitat secundario, el área central está más relacionada con la abundancia de forraje.

### Zona Mínima de Protección Periférica (Minimum Edge Buffer)

Ésta representa el tamaño de la zona de protección relacionado a la distancia necesaria desde aquellas áreas con actividad humana. Por lo tanto, para las áreas de corredores potenciales estas zonas constituyen la mitad del ancho necesario del corredor.

### Aptitud Mínima del Hábitat (Minimum Habitat Suitability)

La inclusión de un modelo de aptitud del hábitat es opcional, pero su uso es muy recomendado. Para cada una de las categorías principales de hábitats/corredores, se puede especificar una aptitud mínima para incluir en esa categoría. Lo que se muestra a continuación es una estrategia general para el desarrollo de esta capa o estrato.

1. Desarrolle mapas de aptitud por separado para cada categoría: hábitat primario, hábitat secundario y corredor potencial. El panel de Aptitud del Hábitat / Distribución de las Especies (Habitat Suitability / Species Distribution) brinda una variedad de herramientas para desarrollar esto empíricamente. Sin embargo, la opción de evaluación multi-criterio (MCE) es usualmente la herramienta elegida, ya que el mapeo de aptitud estará basado en informes publicados sobre asociaciones entre especies y paisajes.
2. Reestablezca el alcance del área perteneciente al mapa de aptitud del hábitat primario en un área de 0,75 a 1,0 con el módulo STRETCH. Luego, reestablezca el área del mapa de aptitud del hábitat secundario en 0,5-0,75; el mapa del corredor potencial primario en 0,25-0,5 y finalmente, el mapa del corredor potencial secundario en 0-0,25. Combine estos cuatro mapas utilizando la opción *cover* en OVERLAY. El resultado será un mapa de una sola capa o estrato con un valor de 0,0 a 1,0. Los umbrales predeterminados en LCM son 0,75; 0,5 y 0,25 para decidir la distribución de terreno en las categorías básicas (antes de considerar los aspectos del área mínima, el cruce del intervalo espacial y la zona de protección periférica). Todas las áreas con un valor de 0 son por definición *no aptas*.

En la práctica, el usuario es libre para establecer cualquier umbral que sea significativo y lógico dentro del contexto de su estudio.

#### *Panel del Cambio del Hábitat y del Análisis del Intervalo Espacial (Habitat Change / Gap Analysis)*

Este panel es utilizado para dos tipos de análisis: un análisis del cambio en el estado del hábitat (creado por medio de una doble ejecución del panel Habitat Assessment) y un análisis del intervalo espacial por medio de la comparación de los resultados del panel Habitat Assessment y un mapa del estrato de protección.

En el caso del cambio en el hábitat, se produce un gráfico de las ganancias y pérdidas que puede ser alterado con un gráfico del cambio neto.

Con el análisis del intervalo espacial, el mapa de protección puede ser una simple imagen booleana que muestra áreas con y sin protección; o bien, un mapa multi-nivel de números enteros que muestra varios niveles de protección. El resultado es simplemente una tabulación cruzada de categorías de hábitats y niveles de protección.

#### *Panel del Análisis del Patrón del Paisaje y del Proceso de Cambios (Landscape Pattern and Change Process Analysis)*

Este panel permite el análisis del patrón del paisaje o del proceso de cualquiera de los mapas de superficie terrestre y de la predicción actual. Las opciones incluyen:

### Entropía Normalizada (Normalized Entropy)

Esta unidad de medida es la Entropía de Shannon, que está normalizada por la entropía máxima para el número de clases de superficies terrestres involucradas. Otro término común para esta medida es Diversidad. Se calcula sobre las inmediaciones cercanas a cada píxel, definidas como zonas de 3x3, 5x5 o 7x7. La fórmula es la siguiente:

$$E = -E(p \cdot \ln(p)) / \ln(n)$$

donde  $p$  es la proporción de cada clase dentro de las inmediaciones,  $\ln$  es el logaritmo natural<sup>89</sup> y  $n$  es el número de clases. El resultado es un índice que va de 0 a 1, donde 0 indica un caso en el cual la superficie terrestre es uniforme dentro de las inmediaciones y 1 indica la máxima diversidad posible de superficies terrestres dentro de las inmediaciones.

### Riqueza Relativa (Relative Richness)

Esta es otra unidad de medida para la diversidad de las clases de superficies, tomada de la siguiente manera:

$$R = n/n_{max} * 100$$

donde  $n$  es el número de clases diferentes presentes en las inmediaciones y  $n_{max}$  es el número máximo de clases posibles.

### Densidad Periférica (Edge Density)

La Densidad Periférica es una simple medida de fragmentación tabulada como el número de pares de píxeles adyacentes dentro de las inmediaciones diferentes entre sí en relación al número máximo de pares diferentes posibles.

### Área de Parches (Patch Area)

El Área de Parches agrupa los píxeles adyacentes de similar categoría de superficie terrestre en parches, calcula sus áreas y produce una imagen donde cada píxel expresa el área del parche al cual pertenece.

### Densidad de los Parches (Patch Compactness)

La Densidad de los Parches agrupa los píxeles adyacentes de similar categoría de superficie terrestre en parches, calcula sus densidades y produce una imagen donde cada píxel expresa la densidad del parche al cual pertenece. La densidad se calcula de la siguiente manera:

$$C = \text{SQRT}(A_p/A_c)$$

donde SQRT es la función de la raíz cuadrada,  $A_p$  es el área del parche en consideración y  $A_c$  es el área del círculo que posee el mismo perímetro que el de dicho parche.

### Proceso del Cambio (Change Process)

La opción del Proceso del Cambio compara el primer mapa de superficie terrestre con el segundo y mide la naturaleza del cambio en proceso dentro de cada clase de superficie terrestre. Esto es realizado mediante un procedimiento de decisión que compara el número de parches de superficie terrestre presentes dentro de cada clase entre los dos períodos de tiempo con los cambios en sus áreas y perímetros<sup>90</sup>. La información de salida se presenta en forma de un mapa donde a cada clase de superficie terrestre se le asigna la categoría del cambio que está experimentando. Las categorías son interpretadas de la siguiente manera:

Deformation (deformación): hay un cambio en la forma.

Shift (movimiento): hay un cambio en la posición.

Perforation (perforación): el número de parches es constante pero el área está decreciendo.

Shrinkage (contracción): el área y el perímetro están decreciendo pero el número de parches es constante.

Enlargement (ampliación): el número de parches es constante pero el área está creciendo.

Attrition (desgaste): el número de parches y el área están decreciendo.

Aggregation (agrupamiento): el número de parches está decreciendo pero el área es constante o está creciendo.

Creation (creación): el número de parches y el área están creciendo.

---

<sup>89</sup> La base 2 de logaritmo es más comúnmente usada en la teoría de las comunicaciones, sin embargo, la diferencia es inmaterial con este procedimiento normalizado.

<sup>90</sup> Esta es una implementación del procedimiento detallado por Bogaert, J., Ceulemans, R. y Salvador-Van Eysenrode, D. (2004) en "Decision tree algorithm for detection of spatial processes in landscape transformation" (Algoritmo de decisión para la detección de procesos espaciales en la transformación del paisaje) Environmental Management (Manejo Ambiental), 33, 1, 62-73.



Dissection (disección): el número de parches está creciendo pero el área está decreciendo.

Fragmentation (fragmentación): el número de parches está creciendo pero el área está decreciendo intensamente. Tenga en cuenta que a pesar de que la información de salida se presenta en forma de un mapa, éste no es espacialmente explícito; es decir, el proceso atribuido a cada categoría de superficie terrestre es uniforme en toda el área de estudio.

## Panel para Mejorar el Polígono del Área de las Especies (Species Range Polygon Refinement)

Este panel permite mejorar los mapas de polígonos de áreas pertenecientes a las distribuciones de las especies desarrollados por expertos quienes dibujan estas áreas sobre las bases de los mapas. Esta información es excepcionalmente valiosa, pero está sujeta a errores como resultado de la imprecisión en los mapas de base, errores de la proyección y de los datos geodésicos y experiencia geográfica limitada (es decir, el experto delinea sólo en las áreas donde tiene experiencia).

El principio subyacente del proceso de mejora es descubrir la lógica ambiental común de las áreas delineadas por el polígono de la especie. Esto se logra por medio de la creación de grupos de condiciones ambientales según una serie de variables ambientales que el usuario piensa pueden caracterizar el nicho de la especie. Luego, se comparan estos grupos con el polígono de la especie para determinar la inclusión proporcional de los grupos dentro de dicho polígono. Los grupos que quedan íntegramente o en gran parte dentro del polígono, se supone que describen los componentes esenciales de ese nicho. Aquellos que quedan mayormente o en gran parte fuera del mismo, se los toma como componentes poco probables. Entonces, el polígono es mejorado por medio de la eliminación de las áreas que quedan por debajo del nivel de seguridad asignado. Además, se brinda otra opción para simplemente realizar un mapa de seguridad que puede usarse conjuntamente con el polígono original del procedimiento Weighted

Mahalanobis Typicality en el panel Suitability / Species Distribution. Esta es la opción predeterminada y la que generalmente recomendamos.

## Variables Ambientales y Desarrollo de Grupos (Environmental Variables and Cluster Development)

El componente principal de este análisis es la producción de grupos ambientales. Para esto, usted necesitará proveer un grupo de variables ambientales que puedan describir las condiciones básicas del medio ambiente. Debido a la técnica de agrupamiento usada, éste está limitado a un máximo de siete variables<sup>91</sup>. Para permanecer dentro de este límite, recomendamos especialmente el uso de Principal Components Analysis (Análisis de los Componentes Principales) como método para reducir un grupo más grande de variables a un grupo más pequeño con componentes altamente informativos. Dicho esto, el usuario debería evitar la inclusión de aquellos componentes con poder explicativo muy bajo.

¿Qué variables deberían usarse? Esto debería decidirse en el contexto de las especies a modelar. Las variables pueden dividirse en gradiente directo, de recursos e indirecto. Los gradientes directos son aquellos que afectan directamente la fisiología de la especie (ej.: la temperatura); los gradientes de recursos son aquellos que se consumen (ej.: el agua, los nutrientes) y los indirectos son aquellos que no tienen un efecto directo sobre la especie pero sí afectan la distribución de un gradiente directo o de recursos (ej.: la elevación, el aspecto). Las variables comúnmente usadas son: elevación, pendiente y aspecto (debido a la relación que éstas tienen con la temperatura y la humedad del suelo), desviación estándar y media anual NDVI (como un informe de las condiciones del hábitat presentes a largo plazo y en forma estacional), desviación estándar y temperatura media anual (como un informe de las variaciones en la disponibilidad de energía), desviación estándar y precipitación media anual (como un informe de las variaciones en la disponibilidad de agua), y por último, temperatura y precipitaciones mínimas y máximas (que representan condiciones ambientales extremas).

## Opciones de Resultados (Output Options)

Hay cuatro opciones de resultados:

---

<sup>91</sup> Hemos probado varios procedimientos de agrupación incluyendo K-Means, Fuzzy ARTMAP y SOM. Sin embargo, la técnica Histogram Peak proporcionada en el módulo CLUSTER de IDRISI resultó tan superior a las demás que decidimos utilizarla a pesar de su limitación en el número de variables independientes que permite usar.

1. Presence (Presencia). Éste es un polígono mejorado del área de la especie donde se eliminan las zonas pobremente asociadas con las principales características ambientales del polígono original.
  2. Presence/Pseudo-Absence (Presencia/Seudo-Ausencia). El resultado es el mismo que el anterior, excepto que las áreas con muy poca probabilidad de estar asociadas con las principales características ambientales del polígono original son tratadas como ausencia, mientras que sólo aquellas que tienen una relación cercana son consideradas como presencia.
  3. Confidence (Seguridad). Ésta es la opción predeterminada y la que generalmente recomendamos. A cada píxel dentro del polígono original se le asigna un valor de seguridad de 0-1 basado en lo bien que éste se ajusta a la naturaleza general de un patrón coherente de condiciones ambientales (tal como se explicará más adelante).
  4. Thresholded Confidence (Seguridad del Umbral). Esta opción es la misma que la anterior excepto que las áreas que están por debajo del nivel de seguridad mínimo especificado son forzadas a tener una seguridad de cero.
- Para todas las opciones, excepto el resultado Confidence, se deberá especificar un umbral (threshold) alto y/o uno bajo para establecer las áreas de presencia o ausencia. Los umbrales predeterminados servirán como una guía general de los valores a utilizar. En general, para la presencia, usted buscará un valor que separe un grupo claro de elementos que se superponen fuertemente con el polígono del área de la especie, mientras que para la ausencia tratará de aislar los elementos que tienen muy poca presencia o ninguna en el polígono. En muchos casos, esto es bastante difícil de hacer, razón por la cual recomendamos el uso de la opción Confidence junto con el procedimiento Weighted Mahalanobis Typicality en el panel Habitat Suitability / Species Distribution. Al usar esta opción, no hace falta tomar ninguna decisión.

También hay una opción de máscara de fondo (background mask), que es bastante importante para el uso de este procedimiento. Si está modelando una especie terrestre y está trabajando en un área con importantes zonas oceánicas, debería suministrar una imagen de máscara para eliminar estas zonas de los cálculos de las áreas proporcionales. Para las especies marinas, obviamente se hace lo contrario.

## Panel de Aptitud del Hábitat / Distribución de las Especies (Habitat Suitability / Species Distribution)

Este panel brinda un juego de herramientas para desarrollar mapas de aptitud del hábitat y distribución de las especies. Las opciones específicas disponibles dependen de la naturaleza de los datos de entrenamiento que serán usados (si existe alguno): sólo presencia, presencia/ausencia, abundancia o ninguna. En todos los casos, deberá especificar un grupo de variables ambientales que definan el hábitat o nicho de la especie.

### Variables Ambientales: Mapeo de la Aptitud del Hábitat (Habitat Suitability Mapping)

Para el mapeo de la aptitud del hábitat, las variables usadas se relacionan en gran medida con los tipos de superficie terrestre del hábitat, la proximidad a las áreas de forraje de verano e invierno, proximidad a zonas con disturbios humanos, etc. Todas las variables especificadas deben ser variables continuas a menos que se use la opción de evaluación multi-criterio (MCE). Para todas las opciones, excepto la opción MCE, las variables categóricas deberían ser convertidas en una serie de capas Booleanas (también conocidas como variables *suplentes*). Cuando se usa MCE, se provee un procedimiento de asignación que le permitirá asignar aptitudes a las clases de variables categóricas. También con la opción MCE, usted podrá agregar restricciones Booleanas.

### Variables Ambientales: Modelado de la Distribución de Especies (Species Distribution Modeling)

Las variables que deben usarse para el modelado de la distribución de especies deberían ser elegidas en el contexto de las especies a modelar. Por lo general, usted incluye variables relacionadas con la disponibilidad estacional e interanual de energía y agua. Los factores comúnmente usados incluyen la elevación y la pendiente (debido a su relación con la temperatura y la humedad del suelo), el primer y el segundo componente principal de la imagen media mensual del Índice de Vegetación de Diferencia Normalizada (NDVI) (como un informe de las condiciones de crecimiento presentes a largo plazo y en forma estacional), el coeficiente a largo plazo de la variabilidad en NDVI (como un informe de la variabilidad interanual) y los primeros dos componentes de la precipitación y la temperatura media mensual.

## Sin Datos de Entrenamiento - MCE (No Training Data – MCE)

La opción Multi-Criteria Evaluation (Evaluación Multi-Criterio) está diseñada para casos en que los datos de entrenamiento no se encuentran disponibles, pero en los cuales sí existen estudios disponibles para guiar el desarrollo de un mapa de aptitud o distribución por medio de una evaluación multi-criterio. Esta opción emplea las técnicas especiales que ofrecen los módulos FUZZY y MCE de IDRISI.

Cuando utilice la opción MCE, el primer paso *muy* importante en el análisis es convertir cada una de las variables ambientales en factores. La diferencia entre estos dos elementos es que una variable no tiene escala con respecto al modelo, mientras que un factor tiene una escala numérica especial que usa un procedimiento directamente relacionado con la expresión de la aptitud. Por ejemplo, si uno estuviera modelando una especie que es sensible a los humanos, podría usarse una capa/estrato que muestre la distancia a los asentamientos humanos. La aptitud sería claramente peor dentro y al lado de las áreas con ocupación humana. Al alejarse de estas áreas, el terreno se vuelve cada vez mejor hasta cierto límite. Una vez que se alcanza una distancia aproximada de 2 kilómetros, ya no tiene sentido alejarse más. En este caso, se habrá alcanzado la aptitud máxima (sobre la base de esta sola variable). Por eso, deberíamos restablecer la escala de la variable de modo que la aptitud sea 0 en el límite del asentamiento humano, aumente en valor hasta alcanzar su máximo a los 2 km. y permanezca en ese valor para todas las distancias mayores. En la transición de la evaluación multi-criterio, este proceso es conocido como *estandarización*, pero en realidad lo que uno hace es transformar los datos en una expresión de pertenencia al grupo difuso de terrenos aptos.

Hay dos opciones para la estandarización: el módulo FUZZY o el módulo ASSIGN de IDRISI. El primero está diseñado para la estandarización de variables continuas como en el ejemplo de arriba, mientras que el segundo está diseñado para la estandarización de variables categóricas. Observe que aquí, en contraste con la estandarización usada en el procedimiento de toma de decisión multi-objetivo de IDRISI, esta estandarización usa una escala de 0.0 a 1.0.

Al igual que con el módulo MCE, hay varias opciones de agrupamiento que indican cómo los factores se combinan para crear un solo mapa de aptitud. La opción predeterminada es la combinación lineal ponderada (WLC), especialmente apropiada cuando desee que los factores se intercambien (es decir, para permitir que las calidades pobres sean compensadas con buenas calidades). El operador Minimum no permite el intercambio y caracteriza cada ubicación en base a su peor calidad. Este es obviamente el operador más conservador. El operador Maximum tampoco permite el intercambio, pero caracteriza cada ubicación en base a su mejor calidad.<sup>92</sup>

## Datos de Presencia (Presence Data)

Los datos de presencia son probablemente la forma más común de datos de entrenamiento para el modelado de especies. Éstos registran dónde la especie ha sido observada, pero no dónde se ha observado que la especie está ausente. Hay tres procedimientos disponibles para manejar estos datos: MaxEnt, Mahalanobis Typicality y Weighted Mahalanobis Typicality.

### MaxEnt

IDRISI brinda una interfaz para el programa MaxEnt para modelar datos de la especie presente. MaxEnt es un modelo de distribución de las especies ampliamente utilizado que emplea un enfoque de entropía máxima para calcular la distribución probable de una especie particular. La entropía máxima es un algoritmo de aprendizaje automático que calcula la distribución probable de una especie en base a la distribución de la entropía máxima sujeta a la siguiente restricción: la media esperada es igual a la media empírica de la distribución. Este método se encuentra dentro de la categoría de un modelo de disponibilidad de uso, ya que emplea una muestra de las condiciones ambientales presentes en la región estudiada (llamada fondo) para definir la distribución probable de la especie. MaxEnt ha sido ampliamente utilizado como modelo para la distribución de las especies presentes ya que posee una exactitud predictiva mayor a la de otros métodos de presencia; sin embargo, se debe tener cuidado cuando existe una parcialidad en la muestra. Una de las ventajas de MaxEnt es que es capaz de representar complejas relaciones entre la especie y los gradientes gracias a su uso de la transformación de las variables llamadas características (ej.: si se

---

<sup>92</sup> Eastman, J. R., W. Jm, P. A. K. Kyem, J. Toledano, 1995. Raster Procedures for Multi-Criteria/Multi-Objective Decisions (Procedimientos Raster para Decisiones con Criterios y Objetivos Múltiples. Photogrammetric Engineering and Remote Sensing (Fotogrametría y Sensores Remotos), 61(5), 539-547.

elige la característica ‘producto’, se utiliza el producto de todas las combinaciones de variables por pares posibles, lo cual permite incluir interacciones simples)<sup>93</sup>

El software MaxEnt desarrollado por Steven Phillips, Miroslav Dudik y Robert Shapire puede descargarse gratuitamente desde [www.cs.princeton.edu/~schapire/maxent/](http://www.cs.princeton.edu/~schapire/maxent/), y debe ser instalado antes de usar esta opción en LCM. No todas las funciones de MaxEnt están disponibles a través de la interfaz de IDRISI. Hemos

seleccionado los parámetros mayormente utilizados y hemos anticipado la inclusión de otros para futuras versiones.

Los parámetros actuales incluyen la opción de la utilización de capas o estratos de proyección para incorporar múltiples realizaciones con diferentes variables ambientales, como por ejemplo el modelado de la predicción. Usted puede seleccionar varios tipos de características para modelar: lineal, cuadrática, producto, umbral y articulación. También puede elegir crear curvas de respuesta e incluir la prueba jackknife (navaja plegable).

### *Tipicidad de Mahalanobis (Mahalanobis Typicality)*

La opción Mahalanobis Typicality supone que la distribución implícita de la especie es normal con respecto a los gradientes ambientales. Sin embargo, nuestras pruebas han mostrado que se desempeña de modo bastante parejo aún con datos moderadamente desvirtuados. El resultado es en forma de probabilidades típicas, una expresión de cuán típico es el píxel de los ejemplos sobre los que fue entrenado. Por eso, un valor de 1.0 indicará una ubicación idéntica a la media de las condiciones ambientales que eran evidentes en los datos de entrenamiento. Sin embargo, tenga cuidado con la interpretación de tipicidades bajas. Debido a que las tipicidades expresan toda la gama de variabilidad, una tipicidad baja puede ser inusual, pero sigue siendo una ubicación legítima que es parte del espacio o área vital de la especie. Si está buscando un umbral para el momento de considerar un área poco probable de formar parte de su espacio vital, probablemente sea un valor muy bajo (ej.: 0.001). Como ilustración de este concepto, considere el caso de una langosta azul. Las langostas azules son muy raras, pero siguen siendo langostas. Para obtener más información, consulte el Sistema de Ayuda online (on-line Help System) para MAHALCLASS.

### *Tipicidad de Mahalanobis Ponderada (Weighted Mahalanobis Typicality)*

Esta opción requiere tanto un archivo de sitio de entrenamiento como un archivo de seguridad (peso). Se pensó que esta opción sería usada con el resultado de seguridad del panel Species Range Polygon Refinement (Mejora del Polígono del Área Vital de las Especies). Una imagen de seguridad/peso contiene valores de 0.0 a 1.0 que expresan el grado de seguridad de que el píxel es verdaderamente un miembro del área vital de la especie. IDRISI usa este archivo junto con un archivo de entrenamiento correspondiente y los envía al módulo FUZZSIG para desarrollar las estadísticas de firmas necesarias para MAHALCLASS. FUZZSIG crea una media ponderada multi-variada y una matriz de varianza/covarianza basadas en los pesos de seguridad.<sup>94</sup>

### *Datos de Presencia / Ausencia (Presence / Absence Data)*

Existen dos enfoques de modelado para los datos de presencia/ausencia: red neural de perceptrones multicapas y regresión logística.

### *Perceptrón Multi-Capas (Multi-Layer Perceptron)*

Esta opción utiliza un subgrupo de opciones disponibles en el módulo MLP y emplea las variables ambientales ya cargadas. Consulte el Sistema de Ayuda online (on-line Help System) para MLP con respecto a esta opción.

<sup>93</sup> S. J. Phillips, M. Dudik y R. E. Schapire, 2004. [A maximum entropy approach to species distribution modeling](#) (Enfoque de la entropía máxima para el modelado de la distribución de las especies). En la Conferencia Internacional “Proceedings of the Twenty-First on Machine Learning” (Procedimientos del Siglo XXI para el Aprendizaje Automático), 655-662.

S. J. Phillips, R. P. Anderson y R. E. Schapire, 2006. [Maximum entropy modeling of species geographic distributions](#) (Modelado de la entropía máxima de la distribución geográfica de las especies). Ecological Modelling (Modelado Ecológico), 190:231-259.

Jane Elith, Steven J. Phillips, Trevor Hastie, Miroslav Dudik, Yung En Chee, Colin J. Yates, 2011. A statistical explanation of MaxEnt for ecologists (Explicación estadística de MaxEnt para ecologistas) Diversity and Distributions (Diversidad y Distribución), 17:43-57.

<sup>94</sup> Sangermano F. e Eastman J.R. A GIS Framework for the Refinement of Species Geographic Ranges (Estrategia SIG para mejorar las áreas geográficas de las especies). International Journal of Geographical Information Science (Publicación Internacional de la Ciencia de Información Geográfica). 2012 (en la prensa).

## Regresión Logística (Logistic Regression)

Esta opción utiliza un subgrupo de opciones disponibles en el módulo LOGISTICREG y emplea las variables ambientales ya cargadas. Consulte el Sistema de Ayuda online para LOGISTICREG con respecto a esta opción.

## Datos de Abundancia (Abundance Data)

Con los datos de abundancia, el único enfoque de modelado es la regresión múltiple. Esta opción usa el módulo MULTIREG de IDRISI y emplea las variables ambientales ya cargadas. Consulte el Sistema de Ayuda online (online Help System) para MULTIREG con respecto a esta opción.

## Formateo de los Datos de las Especies (Species Data Formatting)

Los datos de entrada para este procedimiento pueden ser vectoriales, raster, XY-Text o XY-CSV. XY-Text es un formato de archivo de texto apto para los datos de puntos de presencia, donde cada ubicación está referenciada con las coordenadas X e Y separadas por uno o más espacios o pestañas. XY-CSV (valores separados por una coma) es similar excepto que el par X e Y está separado por una coma. Para todos los demás formatos tabulares, recomendamos que cargue los datos en Database Workshop (Taller para Bases de Datos) y los extraiga como archivos vectoriales. Database Workshop puede aceptar una amplia gama de formatos (incluyendo DBF, MDB, XLS y CSV) y le permite seleccionar y agrupar los mismos antes de volcarlos a una capa/estrato vectorial o raster.

## Panel de Análisis de la Biodiversidad (Biodiversity Analysis Panel)

El panel de Análisis de la Biodiversidad brinda la posibilidad de producir un mapeo espacialmente explícito de:

1. Diversidad Alpha: el número total de las especies consideradas en cada ubicación. Ésta es computada como la riqueza de las especies en cada ubicación; es decir, es el número total de especies encontradas en cada ubicación.
2. Diversidad Gamma: el número total de las especies consideradas en una región grande. Ésta es calculada como la riqueza de las especies dentro de una región. Por lo tanto, el valor registrado en cualquier píxel representa la riqueza dentro de la región a la cual pertenece y no la riqueza en ese lugar particular.
3. Diversidad Beta: la proporción de Gamma para promediar la Diversidad Alpha en una región grande, y por lo tanto, una medida del rendimiento de las especies. Se han propuesto muchas medidas para la Diversidad Beta. La medida usada aquí es la diversidad beta original de Whittaker<sup>95</sup>.
4. Diferencia Sorensen: medida de la diferencia constitucional de las especies. La Diferencia de Sorensen (Sorensen's Dissimilarity) es calculada como 1 menos el Índice de Sorensen, donde este último se computa como el número de especies que son comunes entre el píxel y la región a la cual pertenece, dividido por el promedio alfa dentro de la región.
5. Restricción del Área Vital (Range Restriction): medida continua de la vulnerabilidad que también puede ser interpretada como una medida de endemismo. El Índice de Restricción del Área Vital está basado en una comparación del área donde la especie es relativa a toda la región estudiada. Está pensada para análisis a escala continental o global y debe incluir un archivo de máscara para ocultar las áreas con agua para las especies terrestres o al revés para las especies marinas. El índice oscila de 0 a 1 y los valores altos indican que la mayoría de las especies presentes en esa ubicación tienen áreas vitales restringidas. Tenga en cuenta que el índice es continuo y no depende de un área de umbral para definir la restricción del área vital. La fórmula para calcular el Índice de Restricción del Área Vital es la siguiente:

---

<sup>95</sup> Whittaker, R.H. (1972) "Evolution and measurement of species diversity" (Evolución y medición de la diversidad de las especies), *Taxon*, 21, 213-251.



$$RRI = \frac{\sum_{i=1}^n \left( 1 - \left( \frac{range\_area}{total\_area} \right) \right)^2}{Alpha\_Diversity}$$

En todos los casos, los datos de entrada para este análisis están en forma de polígonos de las áreas vitales de las especies. Se aceptan tres formatos de entrada. El primero es un polígono vectorial compuesto donde todos los polígonos de especies están contenidos dentro del mismo archivo vectorial. El segundo es un archivo vectorial de grupo que incluye los nombres de un grupo de archivos vectoriales que contienen los polígonos del área vital para una sola especie<sup>96</sup>. El tercero es un archivo raster de grupo que incluye un grupo de archivos raster que contienen los polígonos rasterizados del área de una sola especie.

A excepción de la Diversidad Alpha, finalmente los datos deben ser convertidos a un formato raster para el análisis. Por lo tanto, si se provee un archivo vectorial de grupo, cada archivo es rasterizado (usando las características espaciales del archivo de referencia) y un archivo raster de grupo es creado con el mismo nombre que el archivo vectorial de grupo. Si se usa un archivo vectorial compuesto, primero se lo divide y se lo coloca en un grupo de archivos vectoriales separados junto con un archivo vectorial de grupo con el mismo nombre que el archivo vectorial compuesto. Luego, estos archivos vectoriales son rasterizados de a uno por vez.

## Definición Regional (Regional Definition)

Todas las medidas excepto la Diversidad Alpha y el Índice de Restricción del Área Vital requieren la definición de una región sobre la cual se calcula el índice. Hay tres opciones. Las opciones de polígonos regionales vectoriales y raster producirán un mapa donde todos los píxeles dentro de una región (como una ecoregión) tendrán el mismo valor de índice. La opción de zona focal (focal zone), sin embargo, es bastante diferente y puede producir un valor diferente en cada ubicación de los píxeles.

La opción de zona focal calcula valores comparando la composición de la especie en cada píxel con aquellos en una zona circular que lo rodea. Para usar la opción de zona focal, usted debe establecer el diámetro de la zona focal (ej.: 50km.). Esta zona focal es movida sucesivamente sobre cada píxel en la imagen. Como consecuencia, el análisis lleva bastante tiempo para completarse. Los análisis a escala continental con una resolución moderada (ej.: 1km.) son probablemente mejor concretados al final del día de manera que puedan ejecutarse durante la noche.

## Pestaña de Planificación (Planning Tab)

La pestaña de Planificación ofrece herramientas para incorporar intervenciones de planeamiento al proceso de predicción de cambios, junto con una herramienta de planeamiento de corredores para desarrollar corredores biológicos. También hay una interfaz con el software Marxan para el planeamiento de las reservas.

## Panel de Restricciones e Incentivos (Constraints and Incentives Panel)

El panel de Restricciones e Incentivos brinda la habilidad para evaluar los impactos de las áreas de reservas existentes y propuestas, como los incentivos de impuestos para redireccionar el curso del cambio. Estas intervenciones están integradas con el proceso de predicción de cambios. Las restricciones y los incentivos son incorporados por medio de la especificación de un mapa de restricciones/incentivos para cada una de las transiciones en el modelo. Las restricciones y los incentivos son tratados de forma unificada. Los valores de 0 en el mapa son tratados como restricciones absolutas, mientras que los valores de 1 no están restringidos y por lo tanto, no tienen impacto alguno. Los valores menores a 1 pero mayores a 0 actúan como anti-incentivos, mientras que los valores mayores a 1 actúan como incentivos. La forma en que trabaja la función de las restricciones y los incentivos es *multiplicar* los potenciales de transición asociados con cada transición por el mapa de incentivos/restricciones.

<sup>96</sup> Los archivos vectoriales de grupo tienen el mismo formato que los archivos raster de grupo. En la actualidad, los archivos vectoriales de grupo solo se usan para el análisis de la biodiversidad en LCM.

## Panel de Cambios Planeados en la Infraestructura (Planned Infrastructure Changes Panel)

Este panel permite realizar modificaciones en la infraestructura, por ejemplo, desarrollar caminos principales durante el proceso de predicción de cambios. Esta intervención planeada es incorporada por medio de la especificación de mapas de infraestructura y el año en el que se efectivizan. El panel de Distribución de Cambios (Change Allocation) en la pestaña Predicción de Cambios (Change Prediction) revisa esta lista con cada paso de la predicción y agrega un nuevo camino cuando la fecha de la etapa activa es igual o mayor a la fecha de la infraestructura. Además, se pueden desarrollar nuevos componentes de infraestructura al especificar los extremos del camino y permitir al sistema desarrollar las rutas con menor costo de ingeniería.

## Panel de Planificación de Corredores (Corridor Planning Panel)

Este panel se utiliza para construir corredores biológicos. Los datos de entrada primarios son mapas Booleanos de las dos regiones terminales y un mapa de aptitud del hábitat. Los datos de entrada opcionales incluyen un mapa de aptitud del desarrollo, un mapa de valores de conservación y un mapa de terrenos protegidos. Hay opciones para especificar el ancho ideal del corredor y el número de ramales. El primer ramal es por definición el mejor camino. Los ramales sucesivos son de menor calidad.

LCM construye los corredores gracias a un procedimiento de la distancia del costo. El primer paso implica el agrupamiento de los mapas de aptitud/valor. Generalmente, el efecto es tal que el valor de conservación aumenta la aptitud del corredor, mientras que el valor del desarrollo la reduce (aunque solamente en terrenos no protegidos). Una vez creado el mapa de aptitud por agrupamiento, las aptitudes son convertidas en fricciones y se calcula la distancia del costo a partir de una de las regiones terminales. Luego se aplica un sendero de menor costo desde la otra región terminal hasta la primera. Después de esto, se aplica una segunda distancia del costo desde el sendero de menor costo y se determina la relación media entre la distancia del costo y la distancia espacial para establecer un umbral de costo a utilizarse en la construcción del corredor. Si se necesitan construir ramales adicionales, la aptitud de las áreas de los corredores previamente seleccionados se reduce a cero y el proceso es repetido.

## Panel Marxan

La pestaña Planeamiento para Modelar Cambios en el Terreno (Land Change Modeler Planning) ofrece dos paneles Marxan como interfaces para el software del mismo nombre. Este software es gratuito y ha sido desarrollado por la Universidad de Queensland para el planeamiento de la conservación. El mismo brinda técnicas para diseñar y utilizar sistemas de reservas, y también herramientas para desarrollar planos de zonificación multiuso con el objetivo de administrar los recursos naturales. Marxan puede usarse para identificar aquellas áreas que cumplen con la biodiversidad buscada, teniendo en cuenta los costos mínimos.

Este software no está incluido en IDRISI pero puede descargarse en forma gratuita desde el sitio web de la Universidad de Queensland: <http://www.uq.edu.au/marxan>.

## La pestaña REDD Project

La pestaña REDD Project es una herramienta de modelado para calcular la reducción estimada en la emisión de gases de efecto invernadero (GHG) resultante de la implementación de un proyecto para la Reducción de las Emisiones de la Deforestación y Degradación de los Bosques (REDD). Este proyecto es una estrategia para mitigar los cambios climáticos a través de la conservación de los bosques para la retención de carbono. Un componente importante del análisis REDD es la evaluación de los índices y patrones de los cambios históricos en la superficie del terreno, particularmente la deforestación, y también de las fuerzas impulsoras de estos cambios. El análisis REDD emplea los resultados del modelado de la predicción de cambios para estimar el potencial del proyecto en la retención de carbono.

El resultado del análisis REDD es un Documento de Diseño del Proyecto REDD (PDD) que sigue la metodología desarrollada por la organización BioCarbon Fund del Banco Mundial, y luego es enviado a Verified Carbon Standards (VCS) para su aprobación. El PDD consiste en una serie de hojas de cálculo que evalúan el impacto del carbono del proyecto, las filtraciones o escapes y las áreas de referencia para intervalos específicos a lo largo de la vida del proyecto.

El análisis REDD sigue la secuencia de tres paneles en la pestaña REDD Project.

## Panel para Calcular las Emisiones de CO<sub>2</sub> (*Calculate CO<sub>2</sub> Emissions*)

Este panel permite identificar los tipos de reservorios de carbono incluidos en el análisis y también la densidad de carbono presente en los mismos calculada en toneladas de carbono por hectárea (tC ha). En el análisis pueden incluirse seis tipos de reservorios de carbono: sobre el suelo, bajo el suelo, madera muerta, productos de la cosecha de madera, basura y carbono orgánico del suelo. Para todos los reservorios de carbono, excepto aquellos bajo el suelo, hay dos opciones para el ingreso de datos: un valor constante de la densidad de carbono del reservorio o una imagen raster de la densidad de carbono. Cuando se incluye un reservorio de carbono que está bajo el suelo, también existe la opción para especificar la densidad de carbono como un porcentaje del reservorio que está sobre el suelo y la opción para usar el cálculo de Carins<sup>97</sup>.

## Panel para Calcular las Emisiones sin CO<sub>2</sub> (*Calculate Non-CO<sub>2</sub> Emissions*)

Este panel permite incluir las emisiones sin CO<sub>2</sub> cuando la deforestación es producto de incendios. Puntualmente, las emisiones de metano (CH<sub>4</sub>) y óxido nitroso (N<sub>2</sub>O) pueden calcularse por reservorio de carbono, excluyendo los productos de la cosecha de madera y el carbono orgánico del suelo cuando la deforestación es producto del fuego. Para cada clase de superficie terrestre modelada en el proceso de predicción de cambios, la proporción del bosque quemado se especifica junto con el porcentaje quemado para cada uno de los reservorios de carbono sobre el suelo, de madera muerta y de basura. Además, también debe especificarse la eficiencia de la combustión de cada uno de estos tres reservorios de carbono.

## Panel para Calcular las Emisiones Netas de Gases del Efecto Invernadero (*Calculate Net GHG Emissions*)

Este último panel usa la información de las anteriores tablas de REDD para calcular las emisiones netas de gases del efecto invernadero (GHG) basándose en la efectividad estimada del proyecto REDD. Este índice de efectividad se calcula especificando un índice de filtración y un índice de éxito para cada intervalo de informes de REDD. El índice de éxito refleja cuánta deforestación dentro del área del proyecto será prevenida en cada etapa. El índice de filtración representa la cantidad de bosque que será deforestado en el área de filtración como resultado del desplazamiento del área protegida del proyecto. La diferencia de estos dos índices es la efectividad del proyecto REDD para cada intervalo de informes.

A continuación hay una lista de las tablas producidas como resultado del análisis REDD:

1. Lista de reservorios de carbono incluidos o excluidos en la actividad propuesta para el proyecto REDD.
2. Lista de fuentes y gases del efecto invernadero en la actividad propuesta para el proyecto REDD.
3. Lista de clases de superficies terrestres con sus respectivas densidades promedio de carbono por hectárea (tCO<sub>2e</sub> ha) en diferentes reservorios de carbono.
4. Datos de base sobre la actividad de deforestación por clase de superficie terrestre en las áreas del proyecto, de filtración y de referencia.
5. Cambios de base en el almacenamiento del carbono por clase de superficie terrestre en las áreas del proyecto, de filtración y de referencia.
6. Lista de clases de LULC (Land Use/Land Cover – Uso del Terreno/Superficie Terrestre) con sus respectivas emisiones promedio por hectárea (tCO<sub>2e</sub> ha) en diferentes fuentes.
7. Emisiones de base sin CO<sub>2</sub> por clase de LULC en las áreas del proyecto, de filtración y de referencia.
8. Para cada etapa, la información de salida representa el aumento en las emisiones de GHG debidas a filtraciones del área del proyecto. Esto reducirá la efectividad total del proyecto al disminuir la acumulación carbónica de base. Esto se calcula tanto para emisiones con CO<sub>2</sub> como para aquellas sin CO<sub>2</sub>.
9. Para cada etapa, la información de salida representa las disminuciones en las emisiones netas de GHG de origen antropogénico (C-REDD), que explican las reducciones en el carbono de base (C-Baseline) producido por filtraciones (C-Leakage) y el índice de éxito real del proyecto (C-Actual). El cálculo final es:

$$\text{C-REDD} = (\text{C-Baseline}) - (\text{C-Actual}) - (\text{C-Leakage})$$

<sup>97</sup> Cairns, M.A., Brown, S., Helmer, E.H., Baumgardner, G.A. 1997. Root biomass allocation in the world's upland forests (Distribución de la biomasa originaria en los bosques de altura del mundo). *Oecologia*, 111(1), 1-11.



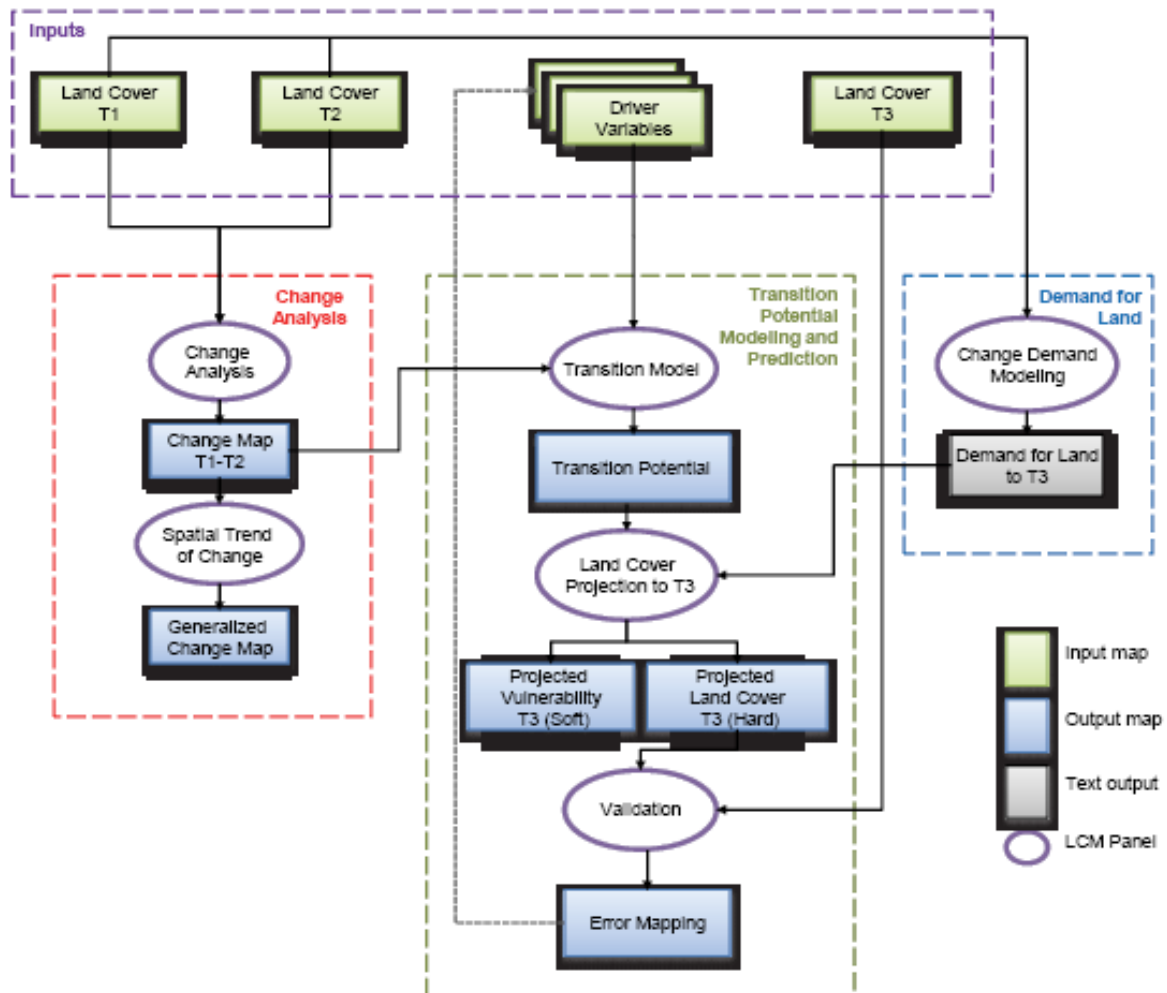
## Referencias Adicionales sobre LCM

Fuller, D. O., Hardiono, M. y Meijaard, E. 2011. Deforestation Projections for Carbon-Rich Peat Swamp Forests of Central Kalimantan, Indonesia (Proyecciones de Deforestación para los Bosques Pantanosos de Turba ricos en Carbono ubicados en Kalimantan Central). Environmental Management (Manejo Ambiental).

Obtenido en [www.ncbi.nlm.nih.gov/pubmed/21359865](http://www.ncbi.nlm.nih.gov/pubmed/21359865).

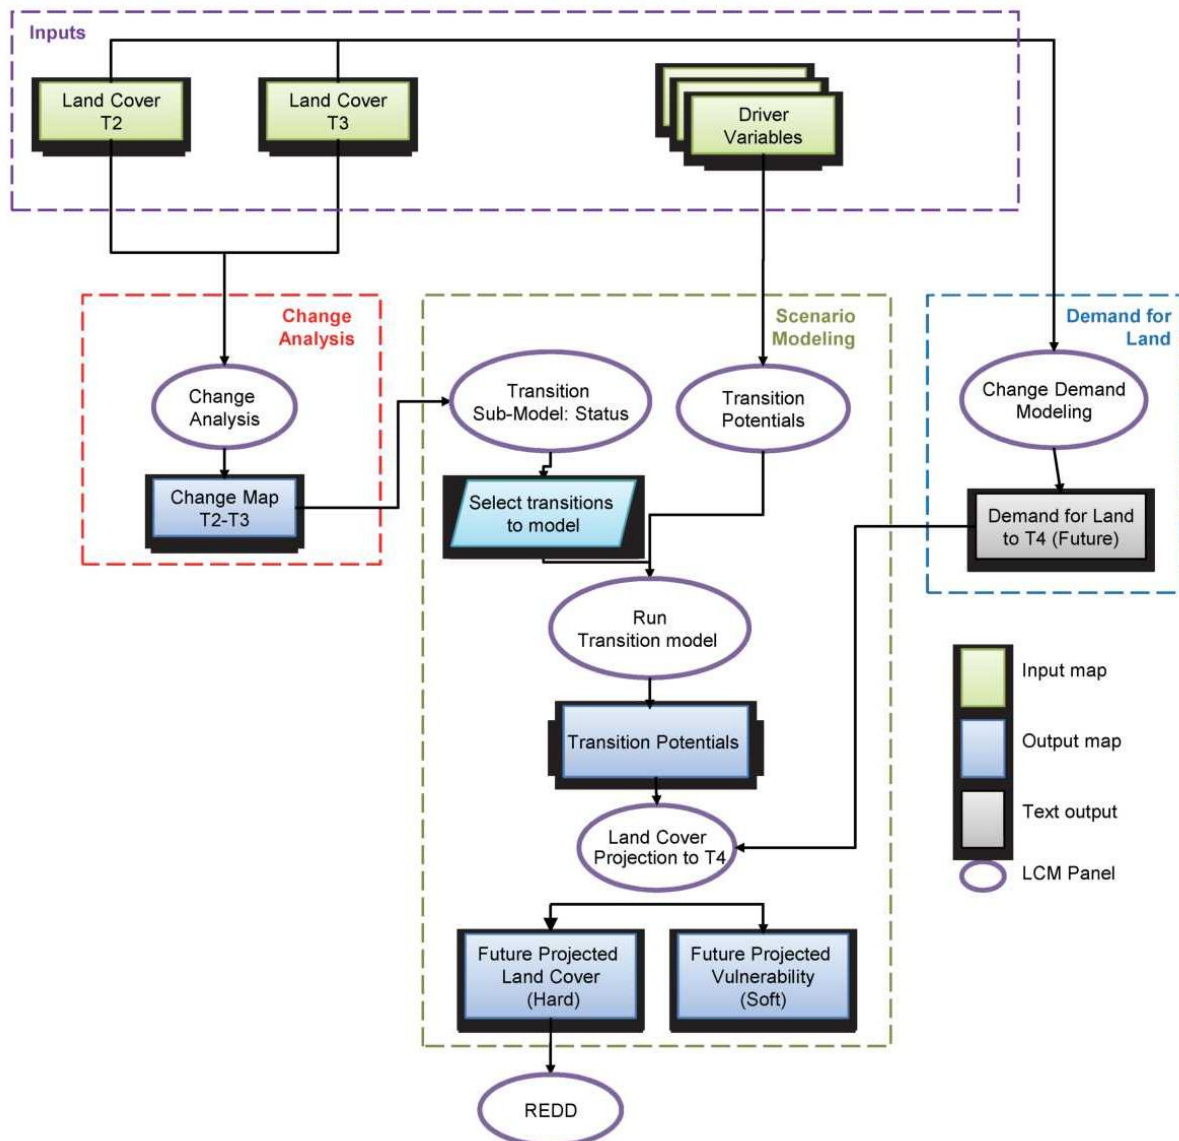
## Análisis de Cambios, Entrenamiento del Modelo y Validación

### Change Analysis, Model Training, and Validation



## Predicción de la superficie terrestre

### Land Cover Prediction



# CAPÍTULO 22 - Modelador de las Tendencias Terrestres

## Introducción

Las series de tiempo de imágenes de observación terrestre proveen un recurso muy importante para entender tanto la dinámica como la evolución de los fenómenos ambientales. Como consecuencia, el Modelador de Tendencias Terrestres (Earth Trends Modeler-ETM) está enfocado en el análisis de las tendencias y las características dinámicas de estos fenómenos evidentes en las imágenes de series de tiempo. Otra particularidad es que el sistema es altamente interactivo con un proceso de exploración que resulta en gran medida un proceso activo. Las tendencias y la dinámica destacadas incluyen:

-- Tendencias Interanuales – tendencias que perduran muchos años o más tiempo del indicado para grandes cambios ambientales. ETM provee herramientas para determinar la presencia de tendencias tanto lineales como monotípicas (no lineales), así como también su significado. Además, las herramientas del análisis de tendencias resisten la presencia de valores atípicos en series de tiempo cortas.

-- Tendencias Estacionales – tendencias en carácter de la progresión estacional del año. Este es un nuevo y revolucionario procedimiento analítico desarrollado para ETM. El eje de la tierra produce una variación anual importante en la energía solar, conduciendo a mayores ciclos estacionales. Sin embargo, los procedimientos tradicionales de análisis de tendencias multi-anales consideran que las estaciones son contaminantes y por lo tanto, las rechazan intencionalmente. Este nuevo procedimiento busca específicamente las tendencias estacionales y las muestra en forma exhaustiva.

-- Componentes Cíclicos – ETM ofrece un procedimiento completamente nuevo para examinar los componentes cíclicos en las series de imágenes de tiempo. Al combinar los elementos del Análisis Fourier y del Análisis de Componentes Principales, ETM provee una forma única de Análisis Espectral Espacio-Temporal, llamado PCA Fourier, que no sólo descubre ciclos aislados sino también patrones de ciclos que suceden conjuntamente. Una etapa final de análisis de correlaciones también muestra cuándo estos patrones son más prevalentes.

-- Patrones irregulares pero recurrentes en espacio/tiempo – ETM ofrece una variedad de herramientas para el análisis de patrones recurrentes en espacio/tiempo incluyendo una forma única de Análisis de Ondulas (Wavelets) y de Análisis de Componentes Principales tanto estandarizado como no estandarizado (también conocido como Análisis de la Función Ortogonal Empírica).


-- Teleconexiones: ETM ofrece herramientas de última generación para el análisis de las teleconexiones climáticas (patrones relacionados de variación entre áreas terrestres ampliamente separadas).

-- Modos Combinados: Una consideración especial en la Ciencia de Sistemas Terrestres es el entendimiento de los modos combinados de variabilidad, como el fenómeno combinado océano-atmósfera El Niño/La Niña. ETM brinda una variedad de herramientas para buscar y examinar estos modos incluyendo el Análisis de Correlación Canónica (Canonical Correlation Analysis-CCA), el PCA Extendido también conocido como EOF Extendido (Extended PCA-Extended EOF), el EOT Extendido (Extended EOT), el MSSA (Análisis del Espectro Singular Multicanal) y el MEOT (Multicanal EOT).

## Recomendación

Recomendamos ampliamente que complete los ejercicios del Tutorial de ETM. Ésta es la forma más rápida para aprender todo el alcance del sistema. Si usted compró IDRISI con la intención principal de trabajar en ETM, también le recomendamos completar la secuencia del Tutorial *Using IDRISI* (Cómo Usar IDRISI), especialmente los ejercicios 1-1 al 1-3.

## Cómo ingresar a ETM / Sus funciones / Recomendaciones de pantalla

Puede ingresarse a ETM desde el ícono en la barra de herramientas principal , desde el Acceso Directo o bien desde el menú Modeling (en el submenú Environmental / Simulation Models). Al igual que el Modelador de

Cambios Terrestres (LCM), ETM se abre en una interfase especial anclada en el lado izquierdo del espacio de trabajo de IDRISI. Recomendamos utilizar un monitor de pantalla ancha (ej.: 1920 x 1200) o una instalación con dos monitores. Sin embargo, para aquellos que tengan monitores de baja resolución, ETM puede minimizarse hacia el borde izquierdo para hacer más espacio haciendo clic en el símbolo “-“ (y de igual manera, el símbolo “+□” para expandirlo).

## ¿No le gusta leer la Documentación? Una alternativa para el usuario

Los usuarios expertos en SIG probablemente puedan descifrar por si mismos la mayoría de los aspectos del ETM. Sin embargo, hay algunos temas importantes que tanto usuarios expertos como principiantes necesitan saber. Deben buscar y prestar mucha atención a las secciones especiales tituladas “Aspectos importantes para saber”.

## Aspectos importantes para saber – ETM en general

1. Las imágenes de series de tiempo se manejan de una nueva manera a partir de la Edición Taiga de IDRISI 16.0. Ahora, una serie de tiempo consiste en un par de archivos. Las series de imágenes (*Image series*) consisten en: un archivo de grupo raster (RGF) que contiene una lista de las imágenes en correcta secuencia temporal y un archivo de documentación de series de tiempo (TSF) que describe la naturaleza de la serie. Como primer paso, usted debe crear el RGF. Puede hacerlo desde IDRISI Explorer: haga click derecho dentro del espacio vacío de la pestaña Files y seleccione la opción Create del menú Context. También se puede crear un RGF con el Collection Editor, ubicado en el menú File, o bien directamente con el módulo Edit del menú Data Entry. Luego cree el archivo de metadatos TSF. Puede hacerlo desde el panel Project en la pestaña Explore de ETM o desde el menú IDRISI File con la opción Create TSF.

2. ETM también reconoce series de Índices. Las series de índices son series de tiempo unidimensionales, tales como el Índice de Oscilación del Sur. Las series de índices también consisten en un par de archivos – un archivo de valores de atributos (AVL) para guardar los datos y un archivo TSF de metadatos. Los archivos AVL generalmente son creados con el módulo Edit. Para las aplicaciones de series de tiempo, el archivo consiste en dos columnas, una columna de identificación y una columna de sección con los datos. Las columnas deben estar separadas por uno o más espacios o por una solapa. En esta versión, la columna de identificación es ignorada. La forma más fácil de crear un AVL es crear las dos columnas en una hoja de cálculo como la de Excel y luego pegar las columnas en el módulo Edit (Editar) del IDRISI (pegar desde Excel a veces tarda un tiempo, pero hay que esperar porque funciona bien). Guardar el archivo como archivo de valores de atributos desde Edit (el programa sabe cómo documentarlo correctamente).

3. Todas las series de tiempo están registradas en ETM como parte de un proyecto de ETM. Los archivos de proyectos de ETM son guardados como archivos de texto con extensión .etm. Los proyectos de ETM se diferencian de los proyectos de IDRISI, los cuales son simplemente una lista de carpetas. Cualquier serie que se registre en ETM deberá ser ubicada dentro de la carpeta de Trabajos (Working Folder) o bien en la carpeta de Recursos (Resource Folder) del proyecto de IDRISI. Recomendamos colocar todas las series en las carpetas de Recursos. Cuando usted busca y selecciona una serie fuera de su proyecto de IDRISI, ETM agrega la carpeta automáticamente a su proyecto como una carpeta de Recursos.

4. Se recomienda comenzar un proyecto con la carpeta de Trabajos vacía y agregar las series de las carpetas de Recursos. Por ejemplo, supongamos que usted está observando las relaciones entre la temperatura de la superficie marina (en una serie llamada “SST”) y la temperatura de la tropósfera inferior<sup>98</sup> (en una serie llamada “TLT”). Imaginemos que su carpeta de Trabajos se llama “d:\análisis”, su serie SST está dentro de una carpeta de Recursos llamada “d:\SST” y la serie TLT está dentro de una carpeta de Recursos llamada “d:\análisis\slt”. Cuando se activan los análisis, ETM coloca los resultados en un grupo de subcarpetas especiales dentro de la carpeta de Trabajos que llevan el mismo nombre que la serie. Por ejemplo, todos los análisis de tendencias de la serie SST irán a una carpeta creada automáticamente por ETM llamada “d:\análisis\sst\tendencia”. De forma similar, los resultados de PCA, Fourier PCA y EOT irán a una subcarpeta llamada “d:\análisis\sst\componentes” y así sucesivamente. Observe que en el caso de su serie TLT, ya existe una carpeta con el mismo nombre de la serie, por lo tanto ubicará los resultados allí (ej.: “d:\análisis\slt\tendencia”, etc.).

---

<sup>98</sup> La tropósfera es la porción de la atmósfera en la cual ocurren los eventos meteorológicos (ej.: tormentas de lluvia). Se extiende aproximadamente hasta la altitud de crucero de las grandes aeronaves.

5. No borre manualmente ninguna carpeta ni archivo relacionado con su serie. Para hacer esto, utilice la opción Advanced Management (Manejo Avanzado) dentro del panel Project (Proyecto) de la pestaña Explore (Explorar). De lo contrario, su proyecto puede alterarse (se puede solucionar, pero lleva tiempo).

6. La mayoría de las operaciones poseen una convención automática de nombramientos basada en un prefijo definido por el usuario y en un sufijo por defecto. Además, en estos casos ETM brindará un prefijo por defecto que es el nombre de la serie. Es seguro aceptar este nombre por defecto. Por ejemplo, si usted realiza un análisis de tendencia Theil-Sen sobre una serie llamada SST, automáticamente brindará el prefijo “sst” y el análisis resultante será nombrado “sst\_ts\_pendiente”. Cuando quiera usar un nombre diferente para no sobrescribir un análisis previo (ej.: con el panel Linear Modeling- Modelamiento Lineal), recomendamos agregar caracteres adicionales al final del prefijo sugerido (sin embargo, usted puede especificar un prefijo completamente nuevo si lo desea).

7. ETM lleva un registro de todos sus análisis para que usted pueda volver a examinar y explorar los resultados en cualquier momento utilizando los respectivos paneles dentro de la solapa Explore. Si una serie no está incluida dentro de alguno de estos paneles, significa que no se han creado anteriormente análisis de ese tipo para esa serie.

8. Al seleccionar una serie, ETM mostrara los nombres de todos los tipos de series que correspondan. Entonces, si se muestran en la lista una serie de índices y una serie de imágenes, se puede seleccionar cualquiera de las dos.

9. Trate de usar nombres cortos para las series (las largas cadenas de análisis pueden generar nombres muy largos luego de agregar todos los sufijos). Además, es tentador crear proyectos que contengan todas las series que usted ha analizado hasta el momento. No ceda a esta tentación, la estructura de proyectos de IDRISI puede volverse bastante compleja y de esa manera hacer más lento el IDRISI Explorer así como también la Pick List (Lista de Selección). Además, si algo sale mal, hay mucho por reconstruir. Es mejor tener muchos proyectos ETM.

10. Muchos componentes analíticos requieren un ajuste para el área que ocupa cada píxel. Si el sistema de referencia es LAT-LONG, es ajuste se realiza automáticamente. De lo contrario, el sistema supone que todas las series de imágenes están en una misma proyección de área. Si esto no es correcto, proyecte sus imágenes de serie con el módulo PROJECT (Proyecto). Esto puede automatizarse para la serie entera usando el Macro Modeler (Modelador Macro) y la opción dynagroup.

## Solapas y Paneles

ETM está organizado alrededor de tres solapas:

Explore (Explorar)

Analysis (Análisis)

Preprocess (Preprocesar)

Dentro de cada solapa hay una serie de paneles desplegados para las etapas analíticas y de tareas. Usted puede tener tantos paneles desplegados abiertos como desee. Son presentados de esta manera solamente para acomodarse a las distintas resoluciones de pantalla.

## La Solapa Explore (Explorar)

El trabajo con series de tiempo es un proceso muy interactivo en ETM. Descubrirá que su necesidad de explorar las series no es solo el punto de partida, sino un continuo proceso de descubrimiento y validación. Todos los paneles en la solapa Explore se relacionan con esta actividad salvo una excepción: el panel Project en el cual usted puede agregar o eliminar series de su proyecto y especificar las máscaras y paletas que prefiera usar en la visualización de las series.

## Aspectos importantes para saber

1. ETM le da la opción de especificar un archivo máscara por defecto para cada serie de imágenes en la grilla del panel de Proyectos. Como todos los archivos máscara de IDRISI, el valor 1 significa que un píxel contiene datos para procesar y un 0 significa que el píxel debe ser ignorado. Si usted ingresa un nombre de archivo máscara en la grilla del panel de Proyectos, éste se mostrará como la máscara por defecto en aquellos paneles de ETM que

contengan una opción de máscara. Sin embargo, tenga en cuenta que puede especificarse cualquier máscara sin importar si ha sido o no incluida en el proyecto de ETM.

2. El panel Explore Space / Time Dynamics (Explorar las Dinámicas de Tiempo y Espacio) le permite examinar tanto series de imágenes como series de índices. Estas últimas se muestran en forma de gráficos pero las series de imágenes aparecen como cubos de tiempo-espacio. Para crear un cubo de tiempo-espacio, muestre la primera imagen en la serie (desde IDRISI Explorer o DISPLAY Launcher). Luego utilice una de las opciones de ampliación automática en el Composer (Herramienta de Composición) para agrandar la primera imagen. Al construir el cubo, ETM agrandará todas las demás imágenes de la serie de la misma manera. Por lo general, debería usarse el botón medio de ampliación si la imagen tiene valores positivos y negativos, y el botón izquierdo de ampliación en caso contrario. Luego de crear el cubo por primera vez, nunca no necesitará crearlo nuevamente (a menos que decida usar otra opción de ampliación, en cuyo caso, debe repetirse la secuencia anterior).

3. Los paneles restantes sólo se usan (y sólo mostrarán opciones de series) luego de realizar uno o más de los análisis de la solapa Analysis (Análisis).

4. Si utiliza la opción automática de sobrecapas vectoriales de la función Advanced Management (Manejo Avanzado) del panel Project, asegúrese que el sistema de referencias de esta sobrecapa sea idéntico al de todas las series.

## El panel Project (Proyecto)

El panel Project le permite establecer, modificar o reutilizar un proyecto existente. Un proyecto consiste en una o más series de tiempo y paletas, archivos máscara y análisis relacionados. Un proyecto ETM se graba en un archivo con una extensión “.etm” en formato de texto y puede ser editado (aunque recomendamos usar la función Advanced Management (Manejo Avanzado) del panel Project para hacer esto). Este archivo de proyecto ETM se guarda en la actual carpeta Working (Trabajos). Como se dijo anteriormente, se recomienda crear los proyectos nuevos dentro de una carpeta Working vacía.

ETM utiliza un concepto de proyecto similar al del Land Change Modeler (Modelador de Cambios Terrestres). Sin embargo, con ETM, el concepto es llevado más allá. Se asigna a cada serie una carpeta Resource (Recursos) especial con el mismo nombre en una subcarpeta de la carpeta Working (Trabajos), sin importar dónde se ubica la serie en realidad. Las subcarpetas poseen nombres tales como:

- “trend” (tendencia) para guardar los resultados de los análisis de tendencias
- “sta” para guardar los resultados de los análisis de tendencias estacionales
- “components” (componentes) para preservar los resultados de PCA/EOF, EPCA, MSSA, EOT, EEOT y MEOT.
- “fourier” para guardar los resultados de PCA Fourier
- “linear-models” (lineal-modelos) para guardar los resultados de modelos lineales

Por lo tanto, si su carpeta de trabajos se llama “d:\time\_series” y usted tiene una serie de imágenes llamada “ndvi8203” (en algún lugar de su proyecto IDRISI), entonces mientras usted realiza diferentes análisis es común ver carpetas creadas automáticamente como “d:\time\_series\ndvi8203\trend” y “d:\time\_series\ndvi8203\ components”, etc.

Utilice los botones Add (Agregar) y Remove (Eliminar) del panel Project (Proyecto) para agregar o eliminar series y especificar máscaras y paletas opcionales por defecto. Para tareas de manejo más detalladas como renombrar o borrar series y análisis, haga clic en el botón Advanced Management (Manejo Avanzado) para abrir un subpanel. Tenga en cuenta que también puede especificar un archivo vectorial en el subpanel Advanced Management que debe superponerse en todos los resultados mostrados.

## El panel Explore Space / Time Dynamics (Explorar las Dinámicas de Tiempo / Espacio)

Este panel le permite explorar visualmente tanto series de imágenes como de índices. Ambas están disponibles en la lista desplegable. Si elige una serie de índices, se visualizará como un gráfico. Al seleccionar una serie de imágenes

se revela una imagen gráfica especial de cuatro dimensiones<sup>99</sup> que será denominada simplemente el *cubo*. La primera vez que usted examine una serie de imágenes con esta función, usted deberá crear los archivos especiales requeridos para el cubo. Usted puede encontrar estos archivos si explora una carpeta que contiene una serie, existen tres y poseen las extensiones de archivo “.bsq”, “.bil” y “.bip”<sup>100</sup>. Si copia una serie en otra carpeta, conviene copiar estos archivos también para evitar tener que volver a crearlos.

Un tema importante en la creación de un cubo de visualización es la ampliación de contraste. ETM basa la ampliación de todas las imágenes de la serie en la configuración de la visualización mínima y máxima de la primera imagen en la serie. Un procedimiento recomendado es mostrar la primer imagen de la serie (ya sea desde el IDRISI Explorer o desde DISPLAY Launcher) y luego usar una de las opciones de ampliación instantánea ubicadas en la parte inferior del Composer (Herramienta de Composición) para agrandarla y maximizar el contraste<sup>101</sup>. Luego, al hacer clic en la función Create / Recreate Visualization (Crear / Recrear Visualización), se usarán los mismos parámetros de visualización para todas las demás imágenes de la serie.

Existen tres modos de visualización para las series de imágenes: cube (cubo), plane (plano) y sphere (esfera). El modo plano es probablemente el menos útil, pero describe mla naturaleza de los datos en forma exacta (en realidad, el usuario observa a través de tres planos del continuum tiempo-espacio. El modo cubo coloca estos planos en las caras más externas del cubo. El modo esfera es evidente en sí mismo, es una versión tridimensional superpuesta en una esfera.

El cubo puede ser manipulado de varias maneras. Si lo sostiene con el mouse le permite moverlo espacialmente. Y las funciones zoom in/out (agrandar/achicar) controlan los detalles. Un clic derecho sobre el cubo inicia un menú de contexto con opciones que son optimizadas para visualizaciones específicas. La función Reset vuelve a la visualización original por defecto.

Dependiendo si se selecciona Time (Tiempo), X ó Y, la función Play/Pause (Activar/Pausar) animará la serie sobre dicha dimensión (esto se aprecia mejor en el modo Plano). Cuando esta función está en la posición Pause, utilice las flechas izquierda y derecha del teclado para moverse de marco a marco. Cuando se encuentra en la posición Play, la animación es automática de acuerdo con el índice de marcos especificado con el selector up/down (arriba/abajo) del diálogo.

El ícono Display (Visualizar) para el cubo le permite observar cualquier visualización específica con máxima resolución. Al seleccionar Time (tiempo), usted selecciona una imagen específica de la serie. Al hacer clic derecho dentro del panel y elegir la opción Orient to X (Oriente a X) ó la opción Orient to Y (Oriente a Y) del menú de contexto, la imagen resultante se denomina Hovmoller<sup>102</sup> o argumento de tiempo-espacio. Una visualización particularmente útil es Orient to Y en la cual la dimensión Y es 0 (el ecuador). En esta visualización, los eventos con movimiento (como la temperatura ó la presión de la superficie marina) asociadas con el fenómeno El Niño se verán como características diagonales en el gráfico.

## Visualización de las Series Secundarias

Muchos de los paneles de la pestaña Explore que muestran gráficos de las series de índices también permiten la superposición de una segunda serie. Para hacer esto, utilice el botón con el símbolo “+” ubicado arriba del gráfico. Cuando se superpone una segunda serie, automáticamente ésta usa un eje Y secundario para hacer más fácil la comparación de la serie. En algunos casos, la comparación es más fácil si se invierte la segunda serie. Una vez visualizada la serie secundaria, aparecerá un botón para invertir las series (series inversion). Podrá usarlo para cambiar la serie secundaria entre el modo normal y el invertido. Además, cuando se abre una serie secundaria, aparece la correlación entre las dos series en el extremo superior derecho encima del gráfico. Un cuadro de entrada indicará que ésta es la correlación del intervalo 0 (es decir, las series están alineadas temporalmente). Para ver la correlación en diferentes intervalos, utilice cualquiera de los dos botones cursores a cada lado de la ventana del intervalo para deslizar la serie secundaria relativa a la original. Esta función le resultará muy útil.

<sup>99</sup> Las dimensiones son 1: X, 2: Y, 3: valor del dato, 4: tiempo.

<sup>100</sup> Estos archivos contienen los tres planos del cubo de visualización. BSQ: secuencia de banda, contiene una sola imagen para cada porción de tiempo. BIL: banda dividida por línea, contiene una porción de tiempo X para la posición en Y. BIP: banda dividida por píxel, contiene una porción de tiempo Y para cada posición X.

<sup>101</sup> Use la opción de ampliación instantánea ubicada en el centro del Composer (Herramienta de Composición) para las series que deben ser simétricas con 0 (ej.: contienen tanto valores positivos como negativos). En caso contrario, use la opción de ampliación instantánea ubicada en el extremo izquierdo.

<sup>102</sup> Llamada así en nombre del climatólogo quien propuso por primera vez la utilidad de esta visualización.

## Panel Explore PCA / EOT/ Fourier PCA / CCA / Wavelets

A excepción de la opción Wavelets (óndulas), este panel es utilizado para ver análisis de descomposición de series realizados previamente. Sólo tiene que indicar qué tipo de análisis desea ver / explorar.

### PCA

El Análisis de los Componentes Principales (Principal Components Analysis), también conocido como Análisis de la Función Ortogonal Empírica) descompone una serie de imágenes en un grupo de componentes subyacentes, ordenados por la cantidad de variación que explican en la serie original. Para cada componente, se ofrecen dos datos de salida: una imagen que muestra el patrón espacial del componente y un gráfico que muestra el grado en el cual el patrón está presente en el tiempo<sup>103</sup>. Se brindan muchas variantes de PCA. Éstas incluyen opciones para computar los componentes en los modos T y S (S-mode y T-mode) y también opciones para centralizar y estandarizar. Además, se ofrecen las siguientes opciones: PCA Extendido (EPCA, también conocido como EEOF) y Análisis del Espectro Singular Multicanal (MSSA). Para más detalles, lea la explicación de PCA en la sección de la pestaña Análisis (Analysis Tab) más abajo.

Todas las series que hayan sido analizadas con PCA serán incluidas en el selector desplegable de series. Seleccione una serie y luego las opciones desplegables adyacentes le mostrarán los análisis específicos. Luego de seleccionar el análisis específico, la carga del componente de la primera visualización aparecerá como un gráfico. Para ver la imagen de componentes asociada, haga clic en el ícono Display (Visualizar) en el extremo superior derecho del cuadro. Si su imagen de componentes posee valores positivos y negativos, se recomienda utilizar la opción de ampliación instantánea simétrica del Composer (el botón central) para lograr una correcta interpretación de la visualización del componente.

### EOT

Un análisis de Teleconexión Ortogonal Empírica (Empirical Orthogonal Teleconnection) también produce una serie de componentes que consiste en dos datos de salida. El gráfico es la propia EOT, mientras que la imagen indica la correlación de la serie con dicha EOT. Al igual que con PCA, se brindan opciones para EOT Extendida (EEOT) y EOT Multicanal (MEOT). Por favor, lea la explicación de EOT en la sección de la pestaña Análisis (Analysis Tab) más abajo.

Todas las series en las que se ha llevado a cabo un análisis EOT figurarán en el selector desplegable de series. Seleccione una serie y luego el cuadro adyacente desplegable mostrará los análisis específicos disponibles. Luego de que usted seleccione el análisis específico, la primer EOT aparecerá como un gráfico. Para ver la imagen de correlación asociada, haga clic en el ícono Display ubicado en el extremo superior derecho del formulario. Si su imagen de componentes tiene valores positivos y negativos (lo cual es muy probable), le recomendamos usar la opción Symmetric Instant Stretch (Extensión Instantánea Simétrica) del Composer (botón del medio) para lograr una correcta interpretación visual de la imagen de correlación.

### Fourier PCA

El análisis Fourier PCA también produce una serie de componentes, pero en este caso con una sola imagen y varias posibilidades de gráficos asociados. El gráfico por defecto es un seudo-periodograma donde el eje X indica números de ondas (*wave numbers*) que van desde la frecuencia más baja de una onda senoidal hasta la más alta con ondas senoidales  $n/2$  en toda la serie (donde  $n$  es el número total de imágenes de la serie). El eje Y indica la amplitud de la onda (como un puntaje del componente). La imagen del componente asociado es aquella con esta combinación de ondas presente (el grado en el cual las ondas se encuentran presentes está representado por sus cargas de amplitud). En el rincón superior derecho del seudo-periodograma hay una lista desplegable donde usted puede elegir concentrarse solo en las frecuencias interanuales (aquellas longitudes de onda más largas que un año) o en las frecuencias subanuales. Además, hay una opción de carga temporal. La carga temporal indica la correlación entre la imagen de carga Fourier PCA y cada una de las imágenes originales de la serie. Por favor, lea la explicación de Fourier PCA en la sección de la pestaña Análisis (Analysis Tab) más abajo.

Todas las series que hayan sido analizadas con Fourier PCA serán incluidas en el selector desplegable de series. Seleccione una serie y luego las opciones desplegables adyacentes le mostrarán los análisis específicos. Luego de seleccionar el análisis específico, un periodograma del primer componente Fourier aparecerá como un gráfico. Para ver la imagen de componentes asociada, haga clic en el ícono Display (Visualizar) en el extremo superior derecho del cuadro. Si su imagen de componentes posee valores positivos y negativos, se recomienda utilizar la opción de ampliación instantánea simétrica del Composer (el botón central) para lograr una correcta interpretación de la visualización del componente.

<sup>103</sup> El análisis de la Función Ortogonal Empírica (EOF) produce exactamente el mismo resultado con la misma interpretación que PCA. Sin embargo, en EOF, el gráfico es llamado componente y la imagen es llamada mapa de carga.



## CCA

El Análisis de Correlación Canónica (Canonical Correlation Analysis-CCA) calcula las relaciones entre pares de series (por ejemplo, entre una serie de la temperatura de la superficie oceánica y una serie de la temperatura atmosférica). Por convención, se conoce a estas dos series como serie independiente (X) y serie dependiente (Y). Sin embargo, estos roles son esencialmente intercambiables. Ambas opciones de modos están disponibles: S-mode y T-mode. En S-mode, las dos series deben coincidir en sus características temporales pero pueden diferir en sus características espaciales. Por el contrario, en T-mode, ambas series deben coincidir en sus características espaciales pero pueden variar en sus características temporales.


Los resultados de un análisis CCA pueden verse desde la pestaña Explore. Seleccione las variables X e Y de los menús desplegables correspondientes. Luego, seleccione el análisis que fue activado desde el menú desplegable CCA. Se pueden elegir tres opciones de visualización desde el menú desplegable Statistics (Estadísticas). La opción Canonical Correlation (Correlación Canónica) muestra las correlaciones entre las variables canónicas correspondientes. Con la opción Variance Explained (Varianza Explicada) se graficará la varianza explicada de las variables canónicas para la serie seleccionada (X o Y). Finalmente, con la opción Variate (Variable) mostrará la verdadera variable canónica en forma de gráfico para la serie seleccionada (X o Y). Con esta opción, se activará el ícono *map* para indicar que usted puede visualizar las imágenes de carga asociadas con cada variable. Se muestran dos imágenes de carga para cada variable. La primera es la carga (correlación) entre la variable y su propia serie (conocida como correlación *homogénea*), mientras que la segunda es la carga entre la variable y la otra serie (conocida como correlación *heterogénea*). Por consiguiente, el análisis CCA resulta muy efectivo para buscar modos combinados entre las series.

## Wavelets


La visualización de óndulas (wavelets) necesita una explicación especial. Las óndulas son utilizadas para muchos propósitos. Una aplicación común es la compresión de datos. Sin embargo, la función aquí es la búsqueda de patrones de eventos anormales a través del tiempo. Alguno de esos patrones podría ser un ciclo perfecto, para el cual el Análisis Fourier resulta una buena herramienta de detección. Un ciclo perfecto es aquél que oscila en forma consistente a través del tiempo, como una onda sinusoidal. Sin embargo, no todas las oscilaciones son perfectas, ni todas son necesariamente ondas sinusoidales o continuas a través del tiempo.

Una óndula es una onda pequeña, o mejor dicho, una onda que aparece brevemente. Éstas pueden ser de cualquier forma. Por ejemplo, uno podría usar una onda sinusoidal como óndula. En la práctica, existen una variedad de óndulas que son utilizadas para finalidades especiales. En ETM, hemos introducido una óndula (wavelet) de Haar Inverso que lleva a una forma muy simple de interpretación en el contexto de series de imágenes de tiempo.

La óndula de Haar Inverso se ve de la siguiente manera:



Este gráfico representa una serie de pesos sobre cuatro muestras adyacentes para un solo píxel en el tiempo. Sin embargo, como el peso de 0 se aplica a todas las muestras de tiempo antes de la primera y después de la cuarta, probablemente resulte más simple pensar en el peso como un par de muestras adyacentes a través del tiempo, como por ejemplo:




Aplicar el filtro de óndula (wavelet) a cualquier píxel nos permite determinar en qué grado está presente la óndula en cualquier momento a través del tiempo. Supongamos que para un píxel en particular tenemos los siguientes valores sobre una secuencia de siete meses:

5 7 15 12 8 9 3

Al mover el filtro hacia las dos primeras posiciones, multiplicamos el 5 por -1 y el 7 por +1. Luego sumamos los resultados y nos da +2. Ahora el filtro se corre una muestra de tiempo hacia la derecha. Multiplicamos el 7 por -1 y el 15 por +1, los cuales al ser sumados dan como resultado +8. Básicamente, lo que estamos diciendo es que la óndula está presente cuatro veces más fuerte en esta segunda posición. Ahora muévelo hacia la derecha un paso más. Aquí notamos algo diferente. Multiplicamos el 15 por -1 y el 12 por +1 lo que resulta en -3 luego de sumar los resultados. Esto implica que la óndula está presente en su orientación opuesta con una amplitud de 3.

¿Por qué resulta esto de interés? Si observa la naturaleza de las operaciones matemáticas llevadas a cabo en cada eslabón de tiempo, es igual a calcular el índice de cambio de un punto en el tiempo al próximo. El resultado del filtro Haar Inverso para las primeras dos fechas indica que el índice de cambio es +2, es decir, una ganancia de dos unidades. Entonces, el filtro resulta en una expresión de ganancias y pérdidas mensuales.

En el próximo paso incrementamos la amplitud del filtro para abarcar cuatro meses:




Al aplicar este filtro, primero sacaremos el promedio de los meses incluidos en cada una de las secciones del filtro de dos meses. Entonces, al realizar esto con los primeros cuatro meses de la serie, el 5 y el 7 son promediados para convertirse en 6 y el 15 y el 12 son promediados para convertirse en 13,5. Luego, al multiplicar el 6 por -1 y sumarle 1 por 13,5 resulta en +7,5. Esto indica que hubo una ganancia de 7,5 unidades entre el primer período de dos meses y el segundo período de dos meses. Luego el filtro se corre solo un mes. Por lo tanto, el próximo cálculo es sobre los meses con valores de 7, 15, 12 y 8, dando como resultado -1. Al mover este filtro solo un mes, se produce lo que se conoce como una Transformación Máxima de Óndula Discreta Superpuesta (MODWT

– Maximal Overlap Discrete Wavelet Transform). El uso de un filtro MODWT tiene la ventaja de poder manejar cualquier longitud de serie (no solo aquellas que tienen longitudes que son potencia de 2) y de reducir en gran medida los artefactos que pueden ser introducidos por la forma del filtro<sup>104</sup>.

Repetir este proceso de aumentar el número de meses en cada mitad del filtro Haar por uno (por lo tanto, el tercer filtro calculará la ganancia entre grupos sucesivos de tres meses) produce lo que se conoce como un análisis de resolución múltiple (a menudo abreviado MRA). Con cada nivel, estamos cambiando a una escala de tiempo cada vez más amplia con dos muestras menos en cada escala (debido a que no poseemos vecinos para calcular la primer y última muestra en cada escala). Si colocamos los resultados de nuestro análisis en forma de un gráfico se origina una pirámide con la cima del período correspondiente a la escala más amplia donde calculamos la ganancia entre la primera mitad de la serie y la última.

<sup>104</sup> Ver el Capítulo 5 sobre Transformación Máxima de Óndula Discreta Superpuesta (Maximal Overlap Discrete Wavelet Transform) en Wavelet en Percival, D.B y Walden, A.T., (2000) Wavelet Methods for Time Series Analyses (Métodos de Óndulas para el Análisis de Series de Tiempo) (Cambridge University Press).



En este ejemplo, observamos el tiempo en el eje X y la escala (expresada como el número de meses en cada mitad del filtro Haar) en el eje Y. En ETM, usted puede mover el mouse sobre el diagrama y se mostrará la fecha, la escala y el valor de óndula (wavelet) que representa cada color.

La importancia de usar el filtro Haar Inverso reside en que los valores que éste calcula tienen una interpretación muy simple: son ganancias en las unidades originales. Por lo tanto, en el ejemplo anterior basado en un análisis de las temperaturas de la superficie marina en el mar Labrador, el valor representa una pérdida 0,89 grados Celsius (porque la ganancia es -0,89).

Observe el intenso enfriamiento ocurrido en 1989. En la escala del mes 1, el enfriamiento solo ocurrió durante unos pocos meses (vista horizontal). Aunque, al mirar verticalmente vemos que su impacto duró aproximadamente 6 años (72 meses). Muchos de los calentamientos y enfriamientos son evidentes en ambas escalas, la más fina y la más amplia. Por lo tanto, tienen una apariencia en forma de árbol en el diagrama de óndulas. Sin embargo, no todos resultan de la misma manera.

En el centro del diagrama, vemos evidencia de calentamiento que no se manifiesta en las escalas más finas. Esto representa un calentamiento muy gradual que se pierde en la variabilidad más alta de las escalas más finas.

## El panel Explore Temporal Profiles (Explorar Perfiles Temporales)

El panel de perfiles temporales permite examinar los valores desde una serie de imágenes para una determinada región de interés. La región de interés puede ser definida como una región de muestra circular o por medio de una característica vectorial

(generalmente un polígono). Entonces, ETM graficará los valores de resumen de todos los píxeles en la región de muestra a través del tiempo. Pueden graficarse valores de resumen medios, medianos, mínimos, máximos, de rango, de sumatoria o de desviación estándar. Además, pueden agregarse líneas de tendencia.

Tenga en cuenta que cualquier perfil puede ser guardado como una serie de índices. Esto puede ser muy útil cuando se usa la herramienta Linear Modeling (Modelamiento Lineal). Por ejemplo, si usted tiene una serie sobre anomalías en las precipitaciones y crea un perfil para una región de interés, mientras la longitud de la serie sea la misma, el perfil guardado puede usarse como la variable independiente. Y una serie de temperatura de la superficie marina puede usarse como la variable dependiente para localizar las áreas en el océano con un patrón similar de anomalías en la temperatura a través del tiempo.

## El panel Explore Series Relationships (Explorar las Relaciones entre las Series)

El panel Explore Series Relationships guarda íconos de análisis de modelamiento lineal ya realizados. Seleccionar la serie de la lista desplegable. Solo se encuentran en la lista aquellas series a las que se ha realizado modelamiento lineal.

Al hacer clic en el ícono se muestran uno o más análisis, dependiendo de qué datos de salida fueron solicitados cuando se realizó el análisis original. Tenga en cuenta que sólo se muestran aquellas imágenes más vistas con mayor frecuencia. Por ejemplo, cuando se eligen las opciones de pendiente y de intersección, sólo se muestra la imagen de pendiente. Para ver otras imágenes relacionadas con su análisis, use el IDRISI Explorer (Explorador del IDRISI) o el DISPLAY Launcher (Iniciador de Visualización) para localizarlas dentro de su proyecto y luego verlas.

## El panel Explore Trends (Explorar las Tendencias)

El panel Explore Trends se utiliza para explorar dos tipos de tendencias: interanuales y estacionales. El subpanel Interannual Trends (Tendencias Interanuales) es similar al panel Explore Series (Explorar Series) ya que también muestra los íconos de los análisis realizados anteriormente. Al hacer clic sobre un ícono se muestra dicho análisis.

El subpanel Seasonal Trends (Tendencias Estacionales) requiere mayor explicación. Si aún no lo ha hecho, lea la sección del panel Seasonal Trend Analyses (Análisis de Tendencias Estacionales) de la solapa Analysis más adelante. El cuadro de diálogo desplegable incluye todas las series a las que se ha realizado un análisis STA. Al hacer clic en el ícono Display (Visualizar), se muestran las imágenes de Fases y Amplitud. Por lo general, las imágenes de Amplitud contienen mayor información.

Tanto en las imágenes de Fases como en las de Amplitud, los colores (excepto el gris neutral) representan las tendencias en la curva estacional. Aunque técnicamente puede crearse una leyenda para estas imágenes, no tiene sentido porque representan tendencias en parámetros seleccionados que describen la forma de estas curvas. Entonces, este panel provee un mecanismo de interpretación interactiva que le permite observar la forma de la curva y ver cómo cambia a través del tiempo.

Las áreas adyacentes que poseen el mismo color en estas imágenes son aquellas que están atravesando cambios similares en las Amplitudes o en las Fases de sus curvas estacionales. Usted puede dibujar una interpretación interactiva de la tendencia definiendo una región de muestra y seleccionando un elemento de tendencia a graficar (las curvas integrales son la opción por defecto)<sup>105</sup>. La región de muestra puede ser definida como una región circular ó seleccionando una característica vectorial. Para las curvas observadas ó integrales, la curva verde muestra la tendencia modelada para el inicio de la serie y la curva roja muestra esta tendencia para el final de la serie. Para todas las demás opciones, se presenta un gráfico del parámetro junto con la pendiente media Theil-Sen.

Una aplicación común de STA es el examen de tendencias en la fenología de la vegetación para el cual usa series de imágenes de índices de vegetación captadas con sensor remoto. Como resultado, se encuentra disponible una salida opcional llamada Green up/down (Verde arriba/abajo). *Green up* se refiere al momento de máximo reverdecimiento, mientras que *green down* se refiere al momento de máxima pérdida de verde (clorofila) en la vegetación. La marca predeterminada está establecida en el punto donde la cantidad de verde excede el 40% de toda la trayectoria desde el verde mínimo hasta el verde máximo. Esto puede cambiarse a cualquier otro valor que se desee. Si se selecciona, esta salida muestra la fecha y hora en que se supera este umbral y el cambio neto en mayor o menor cantidad de verde a través de la serie.

## La Solapa Analysis (Análisis)

La solapa Analysis es el corazón de ETM. Cada uno de los paneles está destinado a un proceso analítico que brindan resultados que pueden ser vistos y revisados desde los paneles de la solapa Explore.

---

<sup>105</sup> El número de los diferentes elementos de tendencia seleccionados afecta la velocidad con que ETM puede calcular la información necesaria. Por ello, por defecto, sólo la información necesaria para las curvas integrales se extrae para la región de muestra. Usted puede seleccionar elementos adicionales usando las casillas opcionales brindadas. Generalmente, la más solicitada es la información de la curva observada.

## Aspectos importantes para saber

1. Por lo general, es importante considerar si el procedimiento a ser utilizado debería ser o no estacional. Por ejemplo, los procedimientos de análisis de tendencias del panel Series Trend Analysis (Análisis de Tendencias de las Series) y de Linear Models (Modelos Lineales) normalmente deberían ser aplicados a series no estacionales. El procedimiento STA *no puede* y el Fourier PCA *no debe* ser aplicado a series no estacionales. EOT y PCA generalmente son aplicados a datos no estacionales, aunque no hay nada que los prevenga de ser utilizados con datos que sean estacionales.

2. Si hay áreas sin datos ni valores de fondo que sirvan para todas las imágenes de una serie, el análisis se realizará más rápido si se especifica una imagen máscara.

## El panel Series Trend Analysis (Análisis de Tendencias de las Series)

Este panel se utiliza para buscar la presencia de tendencias de largo plazo. En la solapa Explore, éstas se denominan tendencias interanuales aunque en realidad, este nombre sólo sería correcto si las series abarcasen más de un año.

ETM ofrece cinco tipos de análisis de tendencias y una forma de prueba del significado de la tendencia:

### Linearity (Linealidad)

Este procedimiento muestra en un mapa el coeficiente de determinación ( $r^2$ ) de una regresión lineal entre los valores de cada píxel a través del tiempo y una serie perfectamente lineal. El resultado es un mapa que muestra hasta qué grado está presente una tendencia lineal.

### Linear Correlation (Correlación Lineal)

Éste dibuja en un mapa la correlación lineal Pearson Product-Moment (Producto- Momento) entre los valores de cada píxel a través del tiempo y una serie perfectamente lineal. Ésta es una forma muy común de análisis de tendencia, aunque es sensible a los ruidos en series cortas.

### Linear Trend (OLS) (Tendencia Lineal)

Éste es el coeficiente de pendiente de una regresión Ordinary Least Squares (Cuadros Menos Comunes) entre los valores de cada píxel a través del tiempo y una serie perfectamente lineal. El resultado es una expresión del índice de cambio por lapso de tiempo. Entonces, si sus datos son mensuales, expresa el índice de cambio por mes.

### Median Trend (Theil-Sen) (Tendencia Media)

Éste es un resistente operador de tendencias sin parámetros altamente recomendado para evaluar el índice de cambios en series cortas o ruidosas<sup>106</sup>. Se calcula determinando la pendiente entre cada combinación de pares y encontrando el valor medio. Por ejemplo, con una secuencia de 20 años de datos mensuales, serán evaluadas un total de 28.680 pendientes en cada píxel. Por lo tanto, lleva mucho más tiempo hacer este cálculo que los procedimientos de tendencias señalados anteriormente. Para las series largas, el resultado es a menudo idéntico al resultado de Tendencia Lineal (OLS). Sin embargo, para series cortas o muy ruidosas, el resultado puede ser bastante diferente y es más confiable. Una característica interesante de la Tendencia Media es su *enlace de ruptura (breakdown bound)*.

El enlace de ruptura para una estadística robusta es el número de valores salvajes que pueden ocurrir dentro de una serie antes de ser afectada. Para la Tendencia Media, el enlace de ruptura es aproximadamente 29%. Por lo tanto, las tendencias expresadas en la imagen deben haber persistido por más del 29% de la longitud de la serie (en lapsos de tiempo).

### Monotonic Trend (Mann-Kendall) (Tendencia Monótona)

Este es un indicador de tendencias no lineales que mide el grado en el que una tendencia aumenta o disminuye consistentemente. Tiene un alcance de -1 a +1. Un valor de +1 indica una tendencia que aumenta continuamente y que nunca disminuye. Cuando tiene un valor de -1, ocurre lo opuesto. Un valor de 0 indica que no hay una tendencia consistente. Se calcula de manera similar a la Tendencia Media. Todas las combinaciones de pares de valores a través del tiempo son evaluadas en cada píxel y se realiza una cuenta con los números que están aumentando o disminuyendo con el tiempo. La estadística Mann-Kendall es simplemente la frecuencia relativa de aumentos menos

<sup>106</sup> Ver HOAGLIN, D.C., MOSTELLER, F. y TUKEY, J.W., 2000, *Understanding Robust and Exploratory Data Analysis* (Comprendiendo el Análisis de Datos Resistentes y Exploratorios), Wiley Classics Library Edition, (Nueva York: Wiley).

la frecuencia relativa de disminuciones<sup>107</sup>.

### Significance of Mann-Kendall (Significado de Mann-Kendall)

Esta opción produce un par de imágenes: una imagen de significado expresada con valores Z y una segunda imagen que expresa la probabilidad de que la tendencia observada haya ocurrido por casualidad. Hablando puntualmente, esta opción está expresando el significado de una tendencia Mann-Kendall. Sin embargo, también es usada comúnmente como una prueba de tendencia para el operador de pendiente media Theil-Sen.

## El panel STA (Seasonal Trend Analysis) (Análisis de Tendencia Estacional)

El análisis de tendencia estacional (STA) es una nueva técnica analítica desarrollada por Clark Labs<sup>108</sup>. Utiliza dos etapas de análisis de series de tiempo para graficar tendencias con la forma de la curva estacional. Puede usarse con cualquier serie que posea características estacionales.

En la primera etapa, cada año de datos es enviado a una regresión armónica para producir los siguientes parámetros de formas:

- Una imagen anual media (a veces llamada Amplitud 0)
- Una imagen que expresa la amplitud del ciclo anual (una onda sinusoidal con un ciclo en el año), conocida como Amplitud 1.
- Una imagen que expresa el ángulo de fase del ciclo anual (una indicación sobre dónde está ubicado el inicio de la serie en una curva sinusoidal). Esto se conoce como Fase 1.
- Una imagen que expresa la amplitud de un ciclo semi-anual (una onda sinusoidal con dos ciclos en el año), conocida como Amplitud 2.
- Una imagen que expresa el ángulo de fase de un ciclo semi-anual (una indicación sobre dónde está ubicado el inicio de la serie en una curva sinusoidal). Esto se conoce como Fase 2.

Estos cinco parámetros pueden describir una familia de curvas excepcionalmente grande. Usando solamente dos armónicas y la media, se eliminan el ruido de alta frecuencia y la variabilidad.

La primer etapa resulta en cinco imágenes por año, una por cada uno de los cinco parámetros de formas. Luego, en la segunda etapa del análisis, se lleva a cabo una tendencia media Theil-Sen en cada uno de los parámetros de forma sobre el número total de años de la serie. Como la tendencia media tiene un enlace de ruptura del 29% de la longitud de la serie, también son eliminadas las tendencias interanuales más cortas que esta longitud. Entonces, el resultado de las dos etapas produce un enfoque en tendencias de largo plazo en la curva estacional mientras que elimina tanto ruidos de alta frecuencia como variabilidades de baja frecuencia.

Para visualizar los resultados de este análisis, se crean dos formas de compuestos de colores: una imagen de Amplitudes y una imagen de Fases (Phases). Cada una se forma asignando imágenes de tendencias seleccionadas con parámetros de forma a los colores primarios rojo, verde y azul. La imagen de Amplitudes asigna RGB a la Amplitud 0, Fase 1 y Fase 2 respectivamente.

La interpretación de estos mapas de tendencias es muy difícil en cuanto a las curvas estacionales. Por ello, ETM posee una herramienta de exploración especial que le permite visualizar las curvas y también la naturaleza de la tendencia. Para mayor explicación, ver la sección del panel Explore Trends (Explorar Tendencias) más arriba. También recomendamos completar el tutorial sobre STA para lograr una interpretación completa de esta herramienta.

<sup>107</sup> Con una estadística Mann-Kendall, la serie de datos es la variable dependiente y el tiempo es la variable independiente. Cuando la variable independiente no es el tiempo, la estadística se conoce como Kendall's Tau. En ese caso, uno mira si las dos variables están aumentando o disminuyendo (conocido como concordancia) ó si una está aumentando mientras la otra disminuye (discordancia) entre cada combinación de pares observados. Tau es entonces la frecuencia relativa de concordancias menos la frecuencia relativa de discordancias.

<sup>108</sup> Ver Eastman y otros, (en periódicos) "Seasonal Trend Analysis of Image Time Series" (Análisis de Tendencias Estacionales sobre Series de Imágenes de Tiempo), *International Journal of Remote Sensing*.

## El panel PCA (Principal Components Analysis/ Análisis de los Componentes Principales) / EOF


El Análisis de los Componentes Principales (PCA) también se conoce como Análisis de la Función Ortogonal Empírica (EOF). Es una técnica muy poderosa para el análisis de la variabilidad a través del tiempo y el espacio y ETM ofrece una gran variedad de variantes incluyendo PCA Extendido (EPCA o EEOF) y Análisis Espectral Singular, Multicanal (MSSA).

### PCA/EOF

Las imágenes en una serie de tiempo están altamente correlacionadas unas con otras de un momento en el tiempo al siguiente. PCA transforma la serie en un grupo de *componentes* ortogonales (es decir, independientes unos de otros) tanto en el tiempo como en el espacio. También están ordenados según la cantidad de variación de la serie que estos explican. En teoría, se pueden producir tantos componentes como las imágenes que tiene una serie original. Sin embargo, en la práctica, casi todas las variaciones pueden ser explicadas solo con un pequeño número de componentes. Los componentes restantes expresan variaciones de ruido y de alta frecuencia.

La manera más fácil de entender PCA es pensar en las series de tiempo de valores para un solo píxel a través del tiempo como un vector. Si usted imagina que cada fecha representa una dimensión, entonces la serie puede describirse completamente con un solo punto en ese espacio. Por ejemplo, imagine tres meses (enero, febrero, marzo) con valores de temperatura media del aire de 15, 18 y 22. En este caso, este punto estaría ubicado en la posición 15 en el eje de enero, 18 en el eje de febrero y 22 en el eje de marzo. Entonces, el vector se forma uniendo este punto con el origen del espacio. Por lo general, necesitamos cientos de dimensiones para describir series de la vida real. Sin embargo, esto es difícil de visualizar, por lo que usaremos el ejemplo de tres.

La imagen está hecha con muchos píxeles, entonces tendremos en realidad un espacio ocupado por muchos vectores (como en la figura de abajo). La correlación entre cualquier par de vectores es inversamente proporcional al ángulo entre ellos (en realidad, el coseno de ese ángulo es igual al coeficiente de correlación). El primer componente es el vector promedio (es decir, un vector que está tan cerca como es posible de toda la colección de vectores). Se conoce como un *eigenvector* (que significa vector *característico*) y su longitud se conoce como *eigenvalor* (eigenvalue), lo que expresa la cantidad de variación que explica. El coseno del ángulo entre este eigenvector y cada píxel vector indica su *carga* (loading) en el componente, es decir, la correlación del píxel vector con el eigenvector.



Luego de haberse calculado el primer componente, sus efectos son eliminados del campo vectorial del píxel<sup>109</sup>. Por lo tanto, los nuevos vectores expresan los residuales después de la eliminación de los efectos del primer componente. Luego, se repite el proceso para extraer el segundo componente, y así sucesivamente. Como cada componente consecutivo está calculado sobre los residuales, todos serán independientes unos de otros. Finalmente, es posible extraer tantos componentes como el número de píxeles vectoriales existentes.

El cálculo eficiente de PCA se hace en realidad con álgebra de matriz y comienza con una matriz de interrelaciones, expresadas como correlaciones o bien como covariaciones. Son posibles dos modos. Si el procedimiento sigue la lógica explicada arriba (conceptualmente), el análisis se realizaría en S-mode y la matriz de entrada sería una matriz cuadrada de la relación entre cada píxel con el resto de los píxeles en el tiempo. Por consiguiente, para una imagen

<sup>109</sup> Aunque el verdadero cálculo de componentes no se realiza de este modo, este paso es equivalente a calcular las correlaciones parciales entre cada par de píxeles vectores, mientras se eliminan los efectos del componente.

con mil píxeles, la entrada sería una matriz de interrelaciones de 1000 x 1000. Éste es el modo dominante empleado por científicos de la atmósfera y del océano. En el análisis S-mode, el componente es un vector (expresado como un gráfico en el tiempo) y las cargas son expresadas como mapas de coeficientes de correlación.

Una segunda opción sería comenzar con una matriz que expresa la relación entre imágenes. Se trata de un análisis T-mode, que constituye el enfoque dominante utilizado por geógrafos. Por ejemplo, con una serie de 300 imágenes, la entrada sería una matriz de correlaciones y covariaciones de 300 x 300 que expresan la relación entre cada imagen con el resto de las imágenes en la serie. Con el análisis T-mode, el componente es una imagen y las cargas son expresadas como un gráfico (es decir, un vector).

En sentido estricto, el procedimiento resumido aquí es un PCA *estandarizado*, ya que las correlaciones expresan las covariaciones entre variables estandarizadas por sus variaciones. También es posible calcular PCA con la matriz variación/covariación como punto de partida en lugar de la matriz de correlación, en cuyo caso se lo llama PCA *no estandarizado*. La diferencia es mínima pero importante. Con un PCA estandarizado, todas las variables son ubicadas en el mismo nivel ya que sus variaciones son efectivamente igualadas. Con un PCA no estandarizado, las variables tienen un valor proporcional a sus variaciones. Para el análisis de imágenes de series de tiempo, hemos descubierto mayormente el PCA estandarizado arroja los resultados de más fácil interpretación. Por lo tanto, éste es el modo predeterminado en ETM.

Otro parámetro de importancia es lo que llamamos *centralización*, que se refiere a la sustracción de un promedio. En el análisis S-mode, el promedio de cada píxel en el tiempo es restado durante el proceso normal de PCA; mientras que en análisis T-mode, el promedio de cada imagen es restado de todos los píxeles de esa imagen. Ésta es una parte natural de las matemáticas del proceso de PCA y es directamente incorporada en las fórmulas que pueden encontrarse en cualquier libro de texto. Sin embargo, la centralización tiene un impacto mayor en el análisis de series de tiempo. La centralización en el espacio (como normalmente se hace en T-mode) elimina la tendencia de los datos en el tiempo; mientras que la centralización en el tiempo (S-mode) elimina la tendencia de los datos en el espacio. La eliminación de la tendencia en el espacio puede interpretarse como un proceso para quitar la geografía no variable en el tiempo. La eliminación de la tendencia en el tiempo puede parecer evidente, pero el tipo de tendencia es en efecto el patrón no variable del espacio en el tiempo.

En la interpretación de los componentes, siempre deben considerarse juntos ambos patrones, espacial y temporal. Uno muestra un patrón (en el espacio o el tiempo) y el otro indica cuándo o dónde estuvo presente. Tenga en cuenta que los valores negativos de los componentes pueden estar asociados con cargas negativas, lo que implica una anomalía positiva.

PCA tiene muchos usos, pero en el análisis de las imágenes de series de tiempo es principalmente una herramienta de exploración. Se destaca su eficacia para organizar las fuentes subyacentes de variabilidad en los datos. Sin embargo, los componentes no son siempre puros. Si en cualquier nivel del análisis hay dos o más fuentes de variabilidad que apenas tienen un mismo valor, entonces PCA tratará de producir componentes mixtos. La solución más común para esto es la *rotación* de los ejes. Existe un número de procedimientos para realizar esto que requieren criterio científico. En ETM, hemos elegido seguir un camino más simple conocido como Telecomunicaciones Ortogonales Empíricas (EOT), que produce un resultado similar a una rotación oblicua de los componentes.

Por último, hablemos de las máscaras. ETM posee la capacidad para especificar una máscara. Esta imagen debe tener 1 en aquellos píxeles que deben incluirse en el cálculo y 0 en los que no. No obstante, esto solo afecta al cálculo de los componentes. Cuando se generan las imágenes de los componentes, la transformación se aplica a todos los píxeles. Usted puede decidir si desea aplicar la máscara a los datos de salida (sencillamente multiplique los componentes por la máscara).

Tenga en cuenta que los resultados de la herramienta PCA pueden visualizarse con la pestaña Explore.

## **EPCA / EEOF**

El análisis PCA Extendido (también conocido como EOF Extendido) permite el análisis de múltiples series de tiempo simultáneamente. Su uso más común es para la búsqueda de modos asociados de variabilidad. Por ejemplo, EPCA puede utilizarse para buscar patrones asociados entre la temperatura de la superficie oceánica, la temperatura troposférica menor y la temperatura troposférica media. Un modo asociado es un patrón que ocurre en múltiples series al mismo tiempo (asumiendo que no es una coincidencia).

EPCA funciona de forma similar a PCA excepto que usted indica el número de series y selecciona el nombre y la máscara para utilizar con cada una. Al igual que con PCA, los resultados pueden visualizarse con la pestaña Explore.



Para cada componente extendido, se mostrará un solo patrón temporal, y para cada serie se verá una imagen de resultado.

Tenga en cuenta que con EPCA no es necesario que cada componente represente un modo asociado. Si los valores en cualquiera de las imágenes no son fuertes, entonces significa que ese componente no posee una presencia importante en esa serie. Además, observe que ETM ofrece alternativas entre S-mode y T-mode, estandarizado y no estandarizado, centralización y no centralización. El significado de estas opciones es el mismo que en PCA.

## MSSA

El Análisis del Espectro Singular Multicanal (MSSA) es un caso especial de EPCA. Al igual que este último, MSSA analiza múltiples series simultáneamente. Sin embargo, en este caso especial, las series involucradas son múltiples versiones de la misma serie, pero en intervalos diferentes. El número de intervalos se conoce como *dimensión incorporada*. Por ejemplo, si la serie comienza en enero y la dimensión incorporada es 3, se asignan tres series a EPCA. La primera comienza en enero, la segunda en febrero y la tercera en marzo. La opción MSSA en ETM realiza todo esto automáticamente y además corta las imágenes de la última parte de las series según sea necesario para hacer que las longitudes de las series coincidan (en el ejemplo dado, la primera serie terminaría en octubre, la segunda en noviembre y la tercera en diciembre). Esta colección de series con intervalos se conoce como *espacio de la fase*, representación de todos los estados posibles de un sistema.

La principal intención de MSSA es buscar patrones que evolucionan tanto en el tiempo como en el espacio. Contrariamente, PCA y EOT asumen que los patrones solo evolucionan en el tiempo. Por lo tanto, MSSA puede usarse para rastrear fenómenos en movimiento. Además, MSSA es un proceso particularmente experto en el análisis de los patrones oscilatorios. En estos casos, los pares de componentes se verán muy similares pero fuera de fase (es decir, no están correlacionados en el intervalo 0 pero están sumamente correlacionados en otro intervalo diferente a 0). Se dice que estos componentes están en *cuadratura* y son de hecho *vectores de base* como el par de seno y coseno del Análisis Fourier y los ejes X e Y del espacio Cartesiano (ejes que, en forma conjunta, pueden describir cada estado posible del sistema). Tenga en cuenta que MSSA solo es capaz de detectar oscilaciones dentro de un período menor o igual a la dimensión incorporada. También observe que generalmente es más fácil interpretar los resultados si la dimensión incorporada es especificada como un número impar. Por consiguiente, si la dimensión incorporada es definida como 5, los resultados incluirán 5 intervalos con 2 períodos de tiempo anteriores, 2 períodos de tiempo posteriores, más el período de tiempo simbolizado por el gráfico temporal. Entonces, para buscar patrones anuales en datos mensuales, la dimensión incorporada sugerida será 13.

## El panel EOT (Teleconexiones Ortogonales Empíricas)

El nombre EOT<sup>110</sup> proviene de su área de aplicación original: el estudio de las teleconexiones climáticas. Sin embargo, esta técnica tiene una utilidad general para la exploración de las imágenes de series de tiempo. Es una técnica de fuerza bruta simple de entender que produce resultados esencialmente idénticos a aquellos que se esperan de un PCA rotado oblicuamente. Las EOT son, por lo tanto, ortogonales en el tiempo pero no necesariamente en el espacio. Observe que al igual que PCA, EOT cuenta con modos extendidos incluyendo EOT Extendida (EEOT) y EOT Multicanal (MEOT).

## EOT

En la implementación estandarizada de EOT por defecto, los píxeles son tratados como vectores en el tiempo. Se examina cada píxel para determinar el grado en el cual su perfil en el tiempo puede explicar la variabilidad de todos los demás píxeles en el tiempo. Realiza esto calculando el coeficiente de determinación (es decir, la correlación al cuadrado) entre el perfil de ese píxel y cada uno de los otros perfiles. Entonces, con los píxeles  $n$ , se realizan análisis de correlación  $n-1$ . Luego se suman los coeficientes de determinación  $n-1$ . Este proceso se repite con todos los píxeles uno por vez, resultando en análisis de correlación  $n(n-1)$ . Al final de este proceso, el píxel con la suma más alta de  $r^2$  se convierte en la ubicación de la primer EOT. El perfil de este píxel a través del tiempo es por lo tanto la primer EOT y los valores están en las mismas unidades que los datos originales.

---

<sup>110</sup> Van den Dool, H. M., Saha, S., Johansson, A., (2000) Empirical orthogonal teleconnections (Teleconexiones ortogonales empíricas). *Journal of Climate*, 13:1421-1435; Van den Dool, H., (2007) *Empirical Methods in Short-Term Climate Prediction* (Métodos Empíricos en la Predicción del Clima a Corto Plazo). Oxford University Press, Nueva York. Tenga en cuenta que RECOMENDAMOS leer este libro. Está escrito excepcionalmente bien y brinda muchas ideas útiles sobre el análisis de series de imágenes de tiempo.

Luego de encontrar la primer EOT, se crea una serie residual y se elimina el efecto de esa EOT. Después, se repite el proceso otra vez para encontrar la próxima EOT. Sin embargo, los valores de la próxima EOT ahora son tomados de la serie residual. Las unidades son las mismas, pero representan anomalías de la primer EOT. Entonces, se toma una serie residual de los residuos y el proceso se repite nuevamente. Una vez calculadas todas las EOTs requeridas (como perfiles temporales), se usa todo el grupo como variables independientes en una regresión múltiple con la serie original para conseguir un grupo de imágenes de correlación parcial para el patrón espacial asociado a cada EOT.

Algunas notas importantes acerca del procedimiento EOT:

1. Como técnica de fuerza bruta, EOT puede tardar bastante tiempo para realizar los cálculos. Si usted toma el caso de una serie global con una resolución de 1 grado, hay 64.800 píxeles. Si usted calcula 10 EOTs, necesita casi 42 mil millones de análisis de correlación. Dependiendo de la resolución de su serie, un análisis comúnmente tarda horas (de hecho, generalmente los realizamos durante la noche).
2. Dada la gran cantidad de dependencia espacial en los datos geográficos, por lo v general recomendamos tomar muestras de los datos en lugar de calcular cada píxel. Un índice de muestra de 1 significa que se quiere computar EOT usando cada píxel. Un índice de muestra de 2 significa que se harán los cálculos usando uno de cada dos píxeles tomados de una de cada dos filas; y así sucesivamente. Recomendamos utilizar un número impar como índice de muestra para que la ubicación de EOT corresponda a un píxel específico.
3. EOT también crea un archivo de punto vectorial que muestra las ubicaciones específicas de cada EOT. Éste llevará el mismo prefijo de los demás datos de salida para el análisis y puede encontrarse en la subcarpeta “componentes” de su serie.

También se brinda una variante no estandarizada de EOT. En este caso, el coeficiente de determinación es evaluado por la variación de cada perfil de píxel durante el cálculo. La diferencia entre EOTs estandarizadas y no estandarizadas es la misma que existe en PCA: la versión estandarizada preferencia la calidad de la relación expresada por la EOT (al dar igual peso a todos los píxeles en sus cálculos), mientras que la versión no estandarizada preferencia las relaciones con magnitud.

## **CEOT**

Se ofrece una segunda variante de EOT que llamamos Cross-EOT (EOT Cruzada) (Van den Dool, 2007 se refiere a ésta como EOT2). Con una EOT común, buscamos en una serie ubicaciones que poseen buen poder de explicación para describir variaciones en otras ubicaciones dentro de la misma serie. Con Cross-EOT buscamos las ubicaciones en una serie que mejor describan las variaciones en otra serie. Por ejemplo, usted puede examinar una serie de temperatura de superficie marina para encontrar ubicaciones que puedan explicar anomalías en las temperaturas terrestres. El único requerimiento es que las dos series tengan la misma longitud y naturaleza (ej.: si una es mensual y tiene 300 imágenes, la otra también debe ser mensual con 300 imágenes). Algunos puntos importantes con Cross-EOT:

1. **TENER MUCHO CUIDADO CON LAS CORRELACIONES FALSAS.** Si observa cada ubicación en una serie y la compara con cada ubicación en otra, hay mucha probabilidad que encuentre alguna ubicación que explique alguna parte de la secuencia en la otra serie. Entonces, es posible crear Cross-EOTs que no tienen significado alguno. Este es un problema compartido por técnicas similares como el Análisis de Correlaciones Canónicas, para el cual se recomienda prefiltrar los datos para enfocarse en los elementos de variabilidad más importantes de la serie. Para esto puede usarse el filtro de ruidos de PCA Inverso en la solapa Preprocessing (Preprocesar).
2. Cross-EOT produce un grupo de gráficos EOT y dos grupos de imágenes: una para cada una de las dos series involucradas.

Tenga en cuenta que los resultados de EOT pueden ser explorados desde la solapa Explore. Además, observe que las EOTs son agregadas automáticamente a su proyecto como series de índices.

## **EEOT**

EOT Extendida (EEOT) es la teleconexión equivalente a EPCA/EEOF. Con EEOT se analizan múltiples series, pero al contrario de CEOT, ésta no trata de encontrar una sola ubicación donde el patrón temporal en una serie pueda explicar la mayor variación en una segunda serie. EEOT busca una ubicación en cualquier serie que pueda explicar la mayor variación en todas las series asociadas en consideración. En esencia, EEOT busca modos asociados entre las series, y su operación es básicamente idéntica a la de EPCA/EEOF. Tenga en cuenta que como EEOT es una

técnica de fuerza bruta, el cálculo puede llevarle mucho tiempo. Por favor, planee considerando esta demora. Sugerimos que haga un análisis inicial en EPCA/EEOF y luego espere hasta que éste pueda procesar los datos durante la noche o el fin de semana.

## MEOT

EOT Multicanal (MEOT) es la teleconexión equivalente a MSSA. MEOT examina múltiples intervalos de una sola serie para encontrar una ubicación en cualquier intervalo que pueda explicar la mayor variación en todos los intervalos combinados. Es idéntica en esencia a MSSA, pero utiliza la lógica de EOT para los cálculos.

El número de intervalos se conoce como *dimensión incorporada*. Por ejemplo, si la serie comienza en enero y la dimensión incorporada es 3, se asignan tres series a EPCA. La primera comienza en enero, la segunda en febrero y la tercera en marzo. La opción MEOT en ETM realiza todo esto automáticamente y además corta las imágenes de la última parte de las series según sea necesario para hacer que las longitudes de las series coincidan (en el ejemplo dado, la primera serie terminaría en octubre, la segunda en noviembre y la tercera en diciembre). Esta colección de series con intervalos se conoce como *espacio de la fase*, representación de todos los estados posibles de un sistema.

Al igual que MSSA, la principal intención de MEOT es buscar patrones que evolucionan tanto en el tiempo como en el espacio. Por lo tanto, MEOT también puede usarse para rastrear fenómenos en movimiento. Además, MEOT es un proceso experto en el análisis de los patrones oscilatorios. En estos casos, los pares de componentes de MEOT se verán muy similares pero fuera de fase (es decir, no están correlacionados en el intervalo 0 pero están sumamente correlacionados en otro intervalo diferente a 0). Se dice que estos componentes están en *cuadratura* y son de hecho *vectores de base* como el par de seno y coseno del Análisis Fourier y los ejes X e Y del espacio Cartesiano (ejes que, en forma conjunta, pueden describir cada estado posible del sistema). Tenga en cuenta que MEOT solo es capaz de detectar oscilaciones dentro de un período menor o igual a la dimensión incorporada. También observe que generalmente es más fácil interpretar los resultados si la dimensión incorporada es especificada como un número impar. Por consiguiente, si la dimensión incorporada es definida como 5, los resultados incluirán 5 intervalos con 2 períodos de tiempo anteriores, 2 períodos de tiempo posteriores, más el período de tiempo simbolizado por el gráfico temporal. Entonces, para buscar patrones anuales en datos mensuales, la dimensión incorporada sugerida será 13. Tenga en cuenta que como MEOT es una técnica de fuerza bruta, el cálculo puede llevarle mucho tiempo. Por favor, planee considerando esta demora. Sugerimos que haga un análisis inicial en MSSA y luego espere hasta que éste pueda procesar los datos durante la noche o el fin de semana.

Tenga en cuenta que los resultados de EOT, EEOT y MEOT pueden visualizarse con la pestaña Explore.

## El panel Fourier PCA Spectral Analysis (Análisis Espectral de Fourier PCA)

Este es un módulo experimental que fue diseñado como una forma de organizar los datos de salida del módulo TFA (Time Series Fourier Analysis - Análisis Fourier de Series de Tiempo). TFA descompone la serie en un grupo de ondas sinusoidales con frecuencias que van desde 1 onda en toda la serie hasta ondas completas  $n/2$ . Esto produce un gran número de imágenes de amplitud y fases. Sin previo interés en ondas específicas, esto puede ser un grupo desalentador de imágenes para examinar. Con Fourier PCA, las imágenes de amplitud de TFA (llamadas automáticamente por ETM) son alimentadas dentro de un PCA no estandarizado. Los componentes de dicho análisis indican patrones de formas de ondas que ocurren comúnmente.

Las cargas en Fourier PCA expresan la fuerza relativa con la que diferentes frecuencias están presentes. Por lo tanto, el eje X representa la frecuencia indicada por el número de la armónica (es decir, un valor de 2 representa dos ondas completas en toda la serie). Esto es similar en espíritu al Periodograma, pero como el eje Y no representa la amplitud directamente, lo llamamos *Seudo-Periodograma*.

Debido a que a menudo resulta difícil comprender el significado de estos patrones de ondas, se ha agregado un análisis adicional al final. Cada componente es correlacionado con cada una de las imágenes originales de la serie. Esto genera una “carga” temporal que expresa cuándo estuvo presente el patrón. Sin embargo, no es una verdadera carga como en un PCA, por lo que la llamamos *Seudo-Carga*.

Algunas notas importantes acerca de Fourier PCA:

1. El análisis no usa información de fases. Por eso, las ondas que ocurren en momentos diferentes son agrupadas conjuntamente. Esto implica que la seudo-carga está limitada en su habilidad para representar íntegramente los tiempos de un patrón. De forma similar, esto supone que la serie puede no parecerse nunca al patrón descripto. El

tutorial ayudará a aclarar esto.

2. Como la información de fases es descartada, en teoría es posible detectar fenómenos en movimiento. Hemos probado esto experimentalmente y hemos tenido éxito en detectar remolinos oceánicos con esta herramienta.

3. Si cualquier par de imágenes de amplitud está correlacionado perfectamente, ó casi perfectamente, se obtiene una sola matriz y el cálculo resulta imposible.

4. Si tiene áreas de fondo, utilice una máscara para dejarlas fuera de consideración. Esto puede reducir la probabilidad de una sola matriz.

5. La frecuencia de interrupción le permite excluir del análisis las ondas de alta frecuencia. El número de interrupción se refiere a la armónica.

Tenga en cuenta que los resultados de PCA Fourier se pueden ver desde la solapa Explore. Además, recuerde que este es un procedimiento experimental y se advierte su uso bajo riesgo propio. Aceptamos sugerencias y comentarios.

## Panel CCA

El Análisis de Correlación Canónica (Canonical Correlation Analysis – CCA) calcula las relaciones entre pares de series (por ejemplo, entre una serie de temperatura de la superficie oceánica y una serie de temperatura atmosférica). CCA lleva a cabo dos análisis de componentes principales, uno para cada serie. De manera que los componentes que produce para cada una (conocidos como *variantes canónicas*) están correlacionados unos con otros al máximo grado posible. Por convención, se conoce a estas dos series como serie independiente (X) y serie dependiente (Y). Sin embargo, estos roles son esencialmente intercambiables. Ambas opciones de modos están disponibles: S-mode y T-mode. En S-mode, las dos series deben coincidir en sus características temporales pero pueden diferir en sus características espaciales. Por el contrario, en T-mode, ambas series deben coincidir en sus características espaciales pero pueden variar en sus características temporales.

Uno de los problemas con CCA en las imágenes de series de tiempo es que las imágenes dentro de cada serie poseen una gran falta de correlación. Esto generalmente conlleva a matrices tan extrañas que no permiten lograr una solución. Una medida que se ha vuelto común en la ciencia atmosférica para resolver esto es usar un procesamiento previo mediante el cual se aplica la función Principal Components (componentes principales) sobre la serie, y los componentes (considerados independientes) son analizados a continuación por CCA<sup>111</sup>. Esto se realiza automáticamente con el uso de CCA en ETM. En realidad, los términos S-mode y T-mode se refieren inicialmente a la naturaleza del procesamiento previo de PCA que se lleva a cabo antes de CCA. Sin embargo, con la función centering (centralizado), el modo seleccionado logra llegar eficazmente a la etapa de CCA.

Los resultados de un análisis CCA pueden verse desde la pestaña Explore, y los procedimientos para realizar esto se encuentran detallados en la sección que describe esa pestaña. La información de salida de CCA incluye:

1. *Variantes Canónicas*: los “componentes” producidos por CCA.
2. *Correlaciones Canónicas*: las correlaciones entre las Variantes Canónicas. CCA se asegura que éstas sean la mayor cantidad posible.
3. *Correlaciones Homogéneas*: las correlaciones entre cada variante y la serie en donde fue calculada.
4. *Correlaciones Heterogéneas*: las correlaciones entre cada variante y la otra serie.
5. *Varianza Explicada*: el grado en el cual cada variante explica la variación presente en la serie de donde fue extraída.

Los patrones fuertemente asociados serán aquellos en los cuales todos estos valores sean altos. Para más información, lea el tutorial de CCA.

---

<sup>111</sup> Para obtener una explicación del uso de S-mode en esta función, lea Barnett, T.P. y Preisendorfer, R. (1987). *Origins and levels of monthly and seasonal forecast skill for United States surface air temperature determined by canonical correlation analysis*. (Orígenes y niveles del pronóstico mensual y estacional de la temperatura del aire en la superficie de Estados Unidos determinada por el análisis de correlación canónica). American Meteorological Society, 115, 1825 - 1850. La implementación de T-mode en ETM es nueva y ha sido desarrollada por N. Neeti.

## El panel Linear Modeling (Modelamiento Lineal)

La herramienta Linear Modeling le permite examinar las relaciones entre las series. Aquí, la serie dependiente es siempre una serie de imágenes mientras que la serie independiente puede ser una serie de imágenes ó bien de índices (pero no mixta). Utiliza análisis de regresión múltiple estándar para generar sus datos de salida y está sujeta a todas las advertencias normales de la regresión que pueden encontrarse en un texto estándar sobre la regresión estadística multivariada.

Uno de los usos principales de la herramienta Linear Modeling es ubicar en un mapa las áreas impactadas por un fenómeno particular como una teleconexión climática tal como El Niño. Si usted está tratando de elegir el patrón de varias teleconexiones, analícelas simultáneamente y seleccione la opción de correlación parcial. Esto producirá una imagen de correlación parcial para cada relación con los efectos de las demás eliminados.

Tenga en cuenta que las relaciones de las series pueden ser analizadas en diferentes intervalos (lags). El intervalo 0 implica que las series dependientes y las independientes son comparadas en lapsos de tiempo correspondiente. Un intervalo negativo cambia una variable independiente a un tiempo anterior. Si piensa en un evento, como el momento pico de El Niño en diciembre, y su variable independiente es un índice para El Niño (como el Índice de Oscilación del Sur), entonces usted observa la relación *antes* del evento original. Puede hacer esto, por ejemplo, para buscar los indicadores principales de El Niño en su serie dependiente. Comúnmente, un intervalo negativo es llamado *guía* (lead) y un intervalo positivo se llama simplemente *intervalo* (lag).

Los resultados de un análisis de Modelamiento Lineal siempre pueden ser reexaminados desde el panel Explore Series Relationships (Explorar las Relaciones de las Series) en la primer solapa. Además, cuando la herramienta Linear Modeling (Modelamiento Lineal) finaliza, le mostrará un resultado como señal de que ha terminado. Sin embargo, en los casos en los que se han seleccionado múltiples datos de salida (como con la correlación parcial) deberá ir al panel Explore Series Relationships para ver todo el grupo de los principales resultados pertinentes. También, como se observó en la sección sobre el panel Explore Series Relationships, algunos datos de salida (como las imágenes de intersección) no son visualizados con los íconos de análisis por lo que deberán ser visualizados desde IDRISI Explorer (Explorador de IDRISI).

## La Solapa Preprocess (Preprocesar)

### El panel Missing Data Interpolation (Interpolación de Datos Faltantes)

Cada imagen de observación tiene comúnmente datos faltantes, en realidad, muchos datos faltantes. La razón más común son las nubes. Aunque la pérdida de información de las transmisiones y las brechas entre las lecturas del escáner también constituyen una fuente de datos faltantes. Sin embargo, muchos de los procedimientos analíticos que brinda ETM son sensibles a la presencia de datos faltantes. El panel Missing Data Interpolation ofrece algunas funciones para mejorar esta situación.

Los datos faltantes son identificados como aquellos que no se encuadran dentro de un rango válido según lo especificado, indicando los valores mínimos y máximos permitidos. Para todas las opciones, usted puede elegir crear una imagen Booleana que defina los píxeles que todavía tienen uno ó más valores faltantes en la serie. Esta es una buena manera de revisar su progreso. Las opciones brindadas para la interpolación incluyen:

### Harmonic Interpolation (Interpolación Armónica)

Esta opción está basada en gran medida en el procedimiento conocido como HANTS (Harmonic Analysis of Time Series – Análisis Armónico de Series de Tiempo) por Roerink y otros (2000)<sup>112</sup>. El procedimiento resulta mejor para llenar con datos faltantes en las áreas de latitud media. No es apropiado para áreas de latitud alta ni regiones desérticas con largos períodos de respuesta uniforme (ej.: cubierta de nieve) ó regiones de selva tropical donde la estacionalidad es dudosa ó extremadamente sutil.

La lógica básica del procedimiento funciona de la siguiente manera. En áreas con latitud media, la curva estacional está muy bien descrita por la combinación aditiva de un pequeño grupo de ondas sinusoidales. Esto se puede

---

<sup>112</sup> Roerink, G.J., Menenti, M. y Verhoef, W., (2000) "Reconstructing Cloudfree NDVI composites using Fourier analysis of time series" (Cómo reconstruir compuestos NDVI libres de nubes usando el análisis Fourier de series de tiempo), *International Journal of Remote Sensing*, 21, 9, 1911-1917.

modelar con Fourier Analysis (Análisis Fourier) ó con Harmonic Regression (Regresión Armónica). Al igual que en el procedimiento HANTS, la Regresión Armónica es usada porque puede ubicar los datos faltantes y porque no requiere que los datos estén a intervalos consistentes, es decir:

$$y = \alpha_0 + \sum_{n=1}^{n=2} \left\{ a_n \sin\left(\frac{2\pi nt}{T}\right) + b_n \cos\left(\frac{2\pi nt}{T}\right) \right\} + e$$

donde  $y$  es el valor de la serie,  $t$  es el tiempo,  $T$  es la longitud de la serie,  $n$  es el número de armónicas a ser usadas en la regresión,  $e$  es una condición de error y  $\alpha_0$  es la media de la serie. Las fechas Julian asociadas con cada paso en el ciclo de la serie (contenidas en el archivo .tsf) brinda la información de tiempo necesaria para la regresión.

Para cada valor faltante en la serie, la regresión armónica utiliza una ventana deslizante de un año, centrada en la fecha faltante. Por lo tanto, el tipo de serie determinará cuántos valores de datos son usados en la regresión. El número de armónicas determinará el número mínimo de valores de datos válidos que deben existir. Por ejemplo, con 2 armónicas por defecto (un ciclo anual y otro semestral), debe existir un mínimo de 5 fechas válidas en la ventana. La fórmula general es  $2n+1$ , donde  $n$  es el número de armónicas. Sin embargo, usted puede especificar un mínimo más alto. Cuantos más datos se incluyan en la regresión, mejor será el ajuste (fit). Usted también puede especificar la apertura máxima (maximum gap) que puede corregirse.

Además de la designación normal de los valores faltantes, el procedimiento de interpolación armónica también le permite designar una tolerancia de error. Luego de un ajuste inicial en una ubicación, si hay un valor válido en esa ubicación y éste se encuentra fuera de la tolerancia especificada, se lo considera como ruido y el píxel es reemplazado por el valor interpolado. Si no desea usar esta función, simplemente especifique una tolerancia imposiblemente alta.

Por último, tenga en cuenta que al igual que el procedimiento HANTS original, usted puede elegir reemplazar cada valor por su estimación ó aproximación interpolada. Esta es una opción esencialmente paliativa.

## Linear Temporal Interpolation (Interpolación Lineal Temporal)

Éste es quizás el procedimiento más simple y que además generalmente funciona muy bien. Cuando se encuentra un píxel con información faltante, éste observa las imágenes anteriores y la imagen posterior a esa fecha hasta el máximo permitido para la falta de información. Si se pueden encontrar buenos valores antes y después de la fecha de la información faltante, y el tiempo entre estas dos fechas no excede la máxima brecha permitida, entonces el procedimiento interpolará linealmente un valor de reemplazo.

## Spatial Interpolation (Interpolación Espacial)

Con la interpolación espacial, ETM observa el vecindario de 3 por 3 que rodea al píxel faltante y lo reemplaza por el valor medio. Esto sólo llenará el píxel si la mayoría de los píxeles vecinos poseen datos válidos.

## Climatology (Climatología) (media temporal)

Los grupos de datos que expresan el promedio a largo plazo de un parámetro en su ciclo a menudo se los llama *climatología*. En el contexto de interpolación de datos faltantes, se refiere al reemplazo de un valor faltante por el valor medio a largo plazo durante ese período en el ciclo. Sólo debe usarse como un método de última instancia ya que resta importancia a la evidencia de las tendencias.

Tenga en cuenta que no se ha establecido un procedimiento de práctica mejorada para la interpolación de datos faltantes. Sin embargo, un procedimiento general que trabaja bien es usar una ó más llamadas sucesivas a los procedimientos de interpolación lineal temporal y espacial seguidos por un paso final de climatología.

## El panel Denoise (Eliminación de Ruidos)

El panel Denoise ofrece varias funciones para la eliminación del ruido en series de imágenes. Las opciones incluyen:

### Temporal Filter (Filtro Temporal)

Ésta opción se afina con el tiempo. Esto se logra usando una ventana de filtro movable simétrico. Las longitudes del filtro pueden ser con números pares e impares excepto en el caso de un filtro Gaussian ó un filtro Maximum (ambos deben ser impares). En el caso de los filtros pares, la primera y la última imagen poseen medio peso cada una en el proceso de filtrado. Las sub-opciones incluyen:

-- Mean filter (Filtro medio) – los valores resultantes de los píxeles son los promedios evaluados de todos los períodos de tiempo dentro de la ventana temporal movable, donde los pesos respetan una distribución Gaussiana. Esto tiende a producir una serie más fina, pero por lo general necesitará una ventana de filtro más ancha que el simple filtro medio.

--Maximum value (Valor máximo) - los valores de los píxeles resultantes representan el máximo valor manifestado en la ventana de filtro temporal.

--Cumulative sum (Suma acumulativa) - los valores de los píxeles resultantes representan la suma del píxel analizado más todos los valores previos que ocurren dentro de la longitud de la ventana de filtro temporal.

--Cumulative mean (Media acumulativa) - los valores de los píxeles resultantes representan el promedio entre el píxel analizado y todos los valores previos que ocurren dentro de la longitud de la ventana de filtro temporal.

### **Maximum Value Composite (Compuesto de Valor Máximo)**

El compuesto de valor máximo se usa comúnmente para las imágenes de índices de vegetación NDVI. La lógica consiste en que la presencia de las nubes (hasta las parcialmente transparentes) siempre conducirá a un valor NDVI más bajo. Entonces, al elegir el valor máximo para el período de tiempo considerado, se puede presumir con seguridad que ha sido menos afectado por las nubes. Tenga en cuenta sin embargo que esta lógica no es necesariamente aplicable a otros tipos de imágenes.

Las herramientas necesarias para crear un compuesto de valor máximo se encuentran dentro del panel Generate/Edit Series (Generar/Editar Series). Por ello, se ofrece utilizar esa opción. Su entrada de acceso está incluida en el panel Denoise (Eliminación de Ruidos) para recordarle al usuario la existencia de esta opción.

### **Inverse PCA (PCA Inverso)**

El Análisis de Componentes Principales No Estandarizados (Unstandardized Principal Components) brinda una transformación lineal de un grupo de componentes donde los primeros componentes describen fuentes de variabilidad altamente frecuentes y coherentes en la serie. Por el contrario, los últimos componentes tendrán fuentes de variabilidad menos importantes e incoherentes como el ruido. Por lo tanto, un medio efectivo para quitar el ruido de los datos (denoising) es revertir la transformación y eliminar los elementos con ruido. ¿Cuántos se deden eliminar? No existe una respuesta fácil sin observar los componentes muy cuidadosamente. Sin embargo, la mayor variabilidad coherente en una serie está contenida en solo unos pocos componentes (los primeros 20 más o menos). Para el filtrado con el propósito de usar Cross-EOT, algunos recomiendan aplicar un filtro aún más pesado y utilizar tal vez los primeros cinco componentes para la reconstrucción de la serie.

Tenga en cuenta que al usar esta opción, ETM calcula automáticamente tanto la transformación directa como la inversa. Además, se pueden utilizar ambos modos de PCA: S-mode y T-mode.

### **Inverse Fourier (Fourier Inverso)**

La lógica de éste es similar a la de PCA Inverso. De la descomposición normal de una serie de imágenes en un grupo de imágenes de amplitud y de fases, es posible reconstruirla usando una transformación inversa. Las armónicas de números más altos representan elementos con frecuencia cada vez más alta como el ruido. Un valor que comúnmente funciona bien es incluir todos los ciclos interanuales, el ciclo anual y el ciclo semestral. La frecuencia límite dependerá de la longitud de la serie. Si, por ejemplo, usted tiene 25 años de datos mensuales, entonces los ciclos interanuales son las armónicas menores de 25, el ciclo anual es la armónica de 25 y el ciclo semestral es la armónica 50. Por lo tanto, el número de armónicas a utilizar será de 50.

## **El panel Deseason (Eliminación de la Estacionalidad)**

Es común querer eliminar la estacionalidad de una serie. Por ejemplo, las medidas de las tendencias del panel Trend (Tendencia) están pensadas para ser usadas con datos no estacionales. Se brindan tres opciones:

### **Anomalies (Anomalías)**

Esta es la forma más comúnmente usada para eliminar la estacionalidad. Como primer paso, ETM crea lo que se llama *climatología* de la serie como un todo. Por ejemplo, si los datos son mensuales, entonces éste crea un enero promedio, un febrero promedio y así sucesivamente. Luego recorre la serie y sustrae el promedio a largo plazo de cada mes. Por ejemplo, la imagen de anomalía de enero de 1998 será igual a enero 1998 menos el promedio a largo plazo de todos los eneros.

## Standardized Anomalies (Anomalías Estandarizadas)

Esta es una variante de las anomalías comunes. En el cálculo de la *climatología* (los promedios a largo plazo), esta variante también calcula la desviación estándar de los valores para cada miembro de la climatología. Luego, cuando las imágenes de anomalías son creadas (sustrayendo el promedio a largo plazo) el resultado es dividido por la desviación estándar para crear una anomalía estandarizada (un puntaje *z*). En este nuevo sistema, un valor de 0 significará que tiene un valor igual al promedio a largo plazo, un valor de +1 significará que es 1 desviación estándar del promedio a largo plazo, y así sucesivamente.

## Temporal Filter (Filtro Temporal)

Esta opción es idéntica al uso del filtrado temporal para la eliminación de ruidos. Sin embargo, aquí la longitud del filtro será lo suficientemente duradera que filtrará tanto los ruidos como la estacionalidad. ETM sugiere una longitud de filtro para cada opción.

## El panel Generate / Edit Series (Generar / Editar Series)

Este panel ofrece un número de funciones útiles para generar nuevas series ó para editar las series ya existentes. Tenga en cuenta que los procedimientos que generan nuevas series le pedirán que seleccione una serie que pueda usarse como plantilla con respecto a todos los parámetros de series tales como el número de imágenes, el tipo de intervalo (ej.: mensual), fecha de inicio y fecha de finalización, etc.

## Linear Index Series (Series de Índices Lineales)

Esta función crea una serie de índices con una secuencia perfectamente lineal con valores que comienzan desde el valor de inicio especificado y aumentan con el incremento especificado en cada intervalo de tiempo. Una serie de este tipo puede resultar útil como una variable independiente que representa una tendencia en el Modelamiento Lineal (Linear Modeling).

## Sin Index Series (Series de Índices Sinusoidales)

Genera una serie de índices con el número especificado de ondas sinusoidales en toda la serie. La serie comienza en el ángulo de fase especificado. Una serie de este tipo puede resultar útil como variable independiente en el Modelamiento Lineal (generalmente en conjunto con una serie Cosenoidal).

## Cos Index Series (Series de Índices Cosenoidales)

Genera una serie de índices con el número especificado de ondas cosenoidales en toda la serie. La serie comienza en el ángulo de fase especificado. Una serie de este tipo puede resultar útil como variable independiente en el Modelamiento Lineal (generalmente en conjunto con una serie Sinusoidal).

## Lagged Series (Series de Intervalos)

Genera una versión con intervalos de la serie de entrada. Al especificar un intervalo diferente de 0 iniciará la serie con la posición indicada, comenzando a contar desde 0. Por ejemplo, para una serie mensual que comienza en enero, al especificar un intervalo de 3 hará que la serie comience en abril y termine con la finalización normal de la serie. Para emparejar una serie sin intervalos de la misma longitud, use la opción *Truncated Series* (Series Truncadas) y elimine del final de la serie el mismo número de imágenes como se especificó para el intervalo. Nota: truncan desde el final de la serie para los intervalos negativos.

## Truncated Series (Series Truncadas)

Crea una versión truncada de la serie de entrada, es decir, una serie recortada al eliminar las imágenes del comienzo ó bien del final de la misma.

## Supplemented Series (Series Complementadas)

Ésta es usada para agregar datos adicionales en el comienzo ó en el final de una serie. Tenga en cuenta que la serie que se agrega (aún si contiene una sola imagen) debe estar documentada correctamente (en su archivo .tsf) con respecto a las fechas de inicio y final de la serie, tipo, etc.

## Skip Factor Series (Series con Factores de Omisión)

Una serie con factores de omisión se utiliza para extraer todos los miembros de una posición específica en un ciclo. Por ejemplo, con una serie mensual que comienza en enero, al usar una *posición inicial* (start position) de 1, un *factor de admisión* (take factor) de 1 y un *factor de omisión* (skip factor) de 11, producirá una nueva serie que consiste en todas las imágenes de enero. Tenga en cuenta que los factores de inicio y de admisión se deben sumar al número de ítems en un ciclo completo. Entonces, por ejemplo, al usar un factor inicial de 6, un factor de admisión de 3 y un factor de omisión de 9, se producirá una serie que consiste en los meses de invierno (junio, julio, agosto) de cada año.



## Rename Series Images (Renombrar las Imágenes de Serie)

Esta función renombra las imágenes dentro de una serie pero no la serie en sí. Para ser consistente con el ordenamiento de archivos del sistema operativo, los nuevos nombres estarán compuestos por un prefijo seguido por el número del ciclo (ej.: año), seguido por la posición (ej.: mes). Esta opción es excelente para renombrar las series que no son ordenadas correctamente por el sistema operativo ó que están enumeradas consecutivamente sin referencia al ciclo ni a la posición.

## Aggregate Series (Agregar Series)

Esta opción agrega series a una resolución temporal más gruesa ó similar. Dependiendo de la naturaleza de la serie, pueden estar disponibles una o varias opciones de conversión (un número pequeño no tiene opciones de conversión debido a las peculiaridades de su naturaleza). Para aquellos casos en que se usa un promedio y los valores deben tomarse de más de una imagen de entrada, se utiliza un promedio valorado (weighted mean).

## Series de Subgrupos (Subset Series)

Esta opción crea una nueva serie como subgrupo espacial de otra serie. Básicamente, ésta realiza el equivalente de la función WINDOW en cada miembro de la serie original.

## El panel Detrend Prewhiten (Eliminar las Tendencias y Blanquear Previamente)

Este panel contiene muchas funciones para eliminar tendencias y manejar correlaciones seriales (correlaciones entre valores sucesivos en el tiempo).

## Detrend (Linear) (Eliminar las Tendencias Lineales)

Esta opción elimina la presencia de una tendencia lineal en la serie. Logra esto extrayendo los residuales de una regresión lineal entre la serie (la variable dependiente) y el tiempo (la variable independiente).

## Detrend (difference series) (Eliminar las Tendencias con diferencias en la serie)

Esta opción crea una nueva serie donde los valores expresan la diferencia entre los valores de la serie original y el valor en el intervalo de tiempo anterior de esa serie. Si la serie es autoregresiva de primer orden (es decir, la correlación entre valores y los valores inmediatamente previos tiene validez para todas las correlaciones sucesivas), este procedimiento eliminará la correlación serial.

## Trend preserving prewhitening (Tendencia que preserva el blanqueo previo)

El Blanqueo Previo se refiere a la eliminación de la correlación serial en el componente erróneo (ruido) de una serie. El procedimiento realizado aquí asume que la serie se puede describir como:

$$Y_t = a + bt + X_t$$

donde:

$$X_t = \rho X_{t-1} + e_t$$

donde  $a$  es una intersección,  $b$  es la pendiente de la tendencia,  $t$  es el tiempo,  $X_t$  es un proceso de ruido rojo en el intervalo 1,  $\rho$  es la correlación serial y  $e$  es un error blanco. El Blanqueo Previo para la Preservación de la Tendencia en ETM utiliza el procedimiento descrito por Wang and Swail (2001)<sup>113</sup> para eliminar el componente con el ruido rojo y produce una nueva serie ( $W$ ) que se puede describir de la siguiente manera:

$$W_t = a' + bt + e'_t$$

donde:

$$a' = (a + \rho b) / (1 - \rho)$$

y

$$e'_t = e_t / (1 - \rho)$$

---

<sup>113</sup> Wang, X. L. y V.R. Swail, 2001. Changes of extreme wave heights in northern hemisphere oceans and related atmospheric circulation regimes (Los cambios de las olas con alturas extremas en los océanos del hemisferio norte y los regímenes de circulación atmosférica relacionados) *Journal of Climate*, 14, 2204-2221.

Se utiliza un procedimiento reiterativo para calcular la verdadera correlación serial  $\rho$ , y la serie blanqueada previamente para preservar la tendencia se calcula como:

$$W_t = (Y_t - \rho Y_{t-1}) / (1 - \rho)$$

Esta serie blanqueada previamente tiene la misma tendencia que la serie original, pero sin correlación serial (Wang y Swail - 2001). Tenga en cuenta que este método de blanqueo previo disminuye el tamaño de la muestra por uno que se recupera mediante la transformación Prais-Winsten (Kmenta, 2004)<sup>114</sup>.

### Durbin Watson

La opción Durbin Watson calcula la estadística Durbin Watson de la correlación serial en el tiempo para cada píxel. Para las series de índices, se realiza una tabulación de la pendiente e intersección de la tendencia lineal más fuerte junto con la estadística Durbin Watson. Su valor siempre se encuentra entre 0 y 4. Un valor de 2 indica que no hay autocorrelación serial. Una estadística Durbin Watson menor a 2 indica evidencia de una correlación serial positiva y una estadística mayor a 2 indica evidencia de una autocorrelación serial negativa. Los valores críticos para la estadística Durbin Watson pueden encontrarse en textos sobre estadística.

### Cochrane-Orcutt

La transformación Cochrane-Orcutt<sup>115</sup> transforma la variable dependiente y cada una de las variables independientes para eliminar la correlación serial. Calcula la correlación serial  $\rho$  de primer orden calculando la correlación entre los residuales y los residuales en el intervalo 1. La transformación de *ambas* variables: la dependiente y la independiente, se calcula de la siguiente manera:

$$X^* = X_t - \rho X_{t-1}$$

Como en el Blanqueo Previo, la transformación Prais-Winsten (Kmenta, 2004) se usa para calcular el valor inicial de las variables transformadas. Tenga en cuenta que se asume que se ha eliminado la estacionalidad de todas las variables para que la intersección esperada sea 0. En este caso también, la intersección transformada es 0. Por lo tanto, el período de la intersección queda fuera de la transformación y el usuario puede utilizar las variables dependiente e independiente transformadas con la herramienta Linear Modeling (Modelamiento Lineal) para completar el análisis.

---

<sup>114</sup> Kmenta, J. 2004. *Elements of Econometrics* (Elementos de la Econometría), The University of Michigan Press.

<sup>115</sup> Cochrane, D., Orcutt, G.H. (1949). Application of Least Squares Regression to Relationships Containing Auto-correlated Error Terms (Aplicación de la Regresión de Rectángulos Menores a las Relaciones que Contienen Períodos de Error Autocorrelacionados). *J Amer Statistical Assoc* 44:32-61.

# CAPÍTULO 23 - Análisis de Costos Anisotrópicos

La modelación de la superficie de costo es ahora una característica conocida de muchos sistemas raster de información geográfica. Al desarrollar una superficie de costo, uno explica el costo del movimiento a través del espacio, donde los costos son una función de los costos estándar (*o base*) asociados con el movimiento y también de las fricciones y fuerzas que impiden o facilitan ese movimiento.

## Costos Isotrópicos

La modelación de la superficie de costo isotrópico se logra en IDRISI con el módulo COST. Dadas ciertas imágenes de entrada de una serie de características de las cuales deben calcularse las distancias de costo y las fricciones que afectan el movimiento, COST produce una superficie de costo que expresa los costos de movimiento en términos de equivalentes de distancia. Entonces, por ejemplo, si una celda tiene un valor de 100, simplemente expresa que el costo del movimiento desde la característica inicial más cercana (objetivo) hasta ese punto es el equivalente del movimiento sobre 100 celdas en el costo base. También se podría originar igualmente del trayecto sobre 100 celdas con una fricción relativa (es decir, relativa a la fricción asociada con el costo de base) de 1, o 50 celdas con fricciones de 2, o 1 celda con una fricción relativa de 100.

## Costos Anisotrópicos

Con el módulo COST, las fricciones poseen efectos idénticos en cualquier dirección. No interesa cómo es el movimiento a través de una celda – su fricción es la misma. A esta fricción se le llama *isotrópica* porque es igual en todas las direcciones. Sin embargo, no resulta difícil pensar en fricciones *anisotrópicas* – elementos de fricción que tienen efectos diferentes en direcciones diferentes. Observe, por ejemplo, el caso de las pendientes. Si imaginamos los costos de una caminata (tal vez en calorías por hora a una velocidad de caminata normal), entonces las pendientes afectan ese costo de manera diferente en direcciones diferentes. Caminar hacia arriba hará que esa fricción actúe con toda su fuerza; caminar de forma perpendicular a través de la pendiente no producirá ningún efecto; y caminar hacia abajo actuará como una fuerza que reduce el costo. El análisis de costo tradicional no puede contener tal efecto.

## Módulos de Costos Anisotrópicos en IDRISI

En IDRISI, se brindan cuatro módulos para la modelación de los costos anisotrópicos. El análisis de costos anisotrópicos es aún un área de análisis bastante nueva, y por ello, alentamos al usuario a enviar información, por escrito, sobre sus aplicaciones y experiencias personales en el uso de estos módulos.

En el centro del grupo hay dos módulos diferentes para el análisis de costos anisotrópicos, VARCOST y DISPERSE (Dispersar), y dos módulos de apoyo para la modelación de fuerzas y fricciones que afectan esos costos, RESULTANT (Resultante) y DECOMP.

El VARCOST modela los efectos de las fricciones anisotrópicas sobre el movimiento de fenómenos que poseen su propia fuerza motora. El ejemplo recién dado de la caminata en la presencia de pendientes es un ejemplo excelente que puede ser perfectamente modelado por VARCOST. El módulo DISPERSE, por otra parte, modela el movimiento de fenómenos que no poseen fuerza motora propia, pero que son afectados por las fuerzas anisotrópicas para dispersarlas en el tiempo. Un buen ejemplo para esto sería un problema de contaminación de fuente puntual tal como un derrame químico sobre la tierra. Luego de la absorción hecha por el suelo, el contaminante se mueve preferentemente con las aguas subterráneas bajo la fuerza de la gravedad según el gradiente hidráulico. El patrón de movimiento resultante tiene forma de nube de humo debido a la probabilidad de movimiento decreciente a medida que la dirección del movimiento se aleja del gradiente máximo (pendiente). DISPERSE y VARCOST son bastante similares en concepto, excepto en cómo cambian las fuerzas y las fricciones en respuesta a cambios en la dirección del movimiento. A esto llamamos la función anisotrópica, que será comentada más abajo. Sin embargo, para comprender dichas funciones, es muy útil repasar las diferencias entre fuerzas y fricciones en el modelado de costos.

## Fuerzas y Fricciones

En la modelación de costos, las fuerzas y las fricciones no son inherentemente diferentes. En todos los procedimientos de modelación de costos – COST (Costo), VARCOST y DISPERSE – las fricciones son expresadas como fricciones relativas usando el costo base como referencia. Entonces, por ejemplo, si se necesitan 350 calorías para caminar sobre terreno llano, y 700 para caminar sobre un terreno más rugoso a igual velocidad, podríamos indicar que el terreno rugoso tiene una fricción de 2. No obstante, si caminásemos cuesta abajo por una pendiente en la que sólo se gasta una energía de 175 calorías, entonces podríamos expresar esto como una fricción de 0,5. Pero, ¿qué son las fricciones menores que 1? En realidad son fuerzas. Para guardar una consistencia, todas las fricciones relativas en IDRISI son expresadas como valores mayores que 1 y las fuerzas relativas son expresadas como valores menores que 1. Por ello, si nos ocupásemos de las fuerzas del viento y si tuviésemos una fuerza base de 10 Km./hora, un viento de 30 Km./hora sería especificado como una fuerza relativa de 0,33.

Con la modelación de costos anisotrópicos, una sola imagen no puede describir la naturaleza de las fuerzas y fricciones que actúan de manera diferente en direcciones diferentes. En cambio, se necesita un par de imágenes – una que describa la magnitud de las fuerzas y fricciones, expresadas como cantidades relativas exactamente como se indicó antes, y otra imagen que describa la dirección de esas fuerzas y fricciones, expresadas como acimut.<sup>116</sup> Entonces, estos pares de imágenes de magnitud/dirección describen un campo de vectores de fuerza/fricción que, junto con la función anisotrópica que se discute abajo, se puede usar para determinar la fuerza o fricción en cualquier dirección y en cualquier punto. El término *par de imágenes de fuerza/fricción* se refiere a una imagen de magnitud y su correspondiente imagen de dirección para las fuerzas (usada con DISPERSE) o bien las fricciones (usada con VARCOST).

Es importante entender la naturaleza de las imágenes de dirección requeridas por VARCOST y DISPERSE. Con VARCOST, la imagen de dirección de la *fricción* debe representar la dirección de movimiento que implica el mayor costo para el movimiento. Por ejemplo, si Ud. está modelando el movimiento de una persona que camina por una campiña, y las fricciones encontradas se deben a la existencia de pendientes (caminar hacia arriba es difícil, caminar hacia abajo es fácil), entonces los valores en la imagen de dirección de la fricción deben formar acimuts desde el norte que apuntan hacia arriba.

Con DISPERSE, la imagen de dirección de la *fuerza* debe representar la dirección en que la fuerza actúa con mayor intensidad. Por ejemplo, si Ud. está modelando la dispersión de un derrame líquido sobre un campo (el flujo hacia abajo es fácil, el flujo hacia arriba es muy dificultosa), entonces los valores en la imagen de dirección de la fuerza deben ser acimut desde el norte que apuntan hacia abajo.

En el uso de VARCOST y DISPERSE, sólo se especifica un par de imágenes vectoriales de fuerza/fricción anisotrópica. Como los análisis pueden implicar un número de fuerzas diferentes que actúan simultáneamente, se ha incorporado un par de módulos para permitir la combinación de fuerzas o fricciones. El primero de estos es el RESULTANT. Éste toma la información de dos pares de imágenes de fuerza/fricción para producir un nuevo par de imágenes de fuerza/fricción que exprese el vector resultante producido por su acción combinada. Entonces, RESULTANT puede usarse para combinar sucesivamente fuerzas y fricciones para producir un solo par de imágenes de magnitud/dirección para utilizar como entrada en VARCOST o DISPERSE.

El segundo módulo que puede usarse para manipular pares de imágenes de fuerza/fricción es el DECOMP. Éste puede descomponer un par de imágenes de fuerza/fricción en sus imágenes componentes X e Y (es decir, la fuerza/fricción en X y la fuerza/fricción en Y). También puede recomponer los componentes de fuerza/fricción X e Y en pares de imágenes de magnitud y dirección. Entonces, DECOMP podría usarse para duplicar la acción del RESULTANT.<sup>117</sup> No obstante, un uso bastante diferente e importante de DECOMP es con la interpolación de los vectores de fuerza/fricción. Si uno toma el ejemplo de los vientos, no es posible interpolar los datos en ubicaciones puntuales para producir una imagen debido a que las rutinas tales como TREND e INTERPOL no pueden distinguir que la diferencia entre 355 y 0 grados es la misma que entre 0 y 5. En cambio, si se construye un par de imágenes raster de los datos de fuerza/fricción puntuales y luego se descompone en los componentes X e Y (usando DECOMP), estas imágenes componentes sí pueden ser interpoladas (Ej.: con TREND) y luego recompuestas en un par de fuerza/fricción usando DECOMP.

<sup>116</sup> El acimut expresa las direcciones en grados, en sentido horario desde el norte. En IDRISI, también se permite expresar un acimut con el valor de -1 para indicar que no hay ninguna dirección definida.

<sup>117</sup> Para llevar a cabo un proceso similar al RESULTANT, se emplea DECOMP para descomponer todos los pares de imágenes de fuerza/fricción que afectan un área en sus componentes X e Y. Estas imágenes componentes X e Y luego son sumadas para generar un par resultante X e Y. La opción recomposition (recomposición) de DECOMP se usa con éstas para producir un par de imágenes resultantes de magnitud/dirección.

## Funciones Anisotrópicas

Con los pares de imágenes de fuerza/fricción, uno tiene una indicación tanto de la magnitud como de la dirección con las que actúan las fuerzas y las fricciones. Sin embargo, ¿cuál es la interpretación de la dirección? Si una fuerza actúa a 45° (noreste), ¿significa esto que actúa por completo a 45° y para nada a los 44°? La respuesta a esto no se determina tan fácilmente y depende finalmente de la aplicación.

Si se toma el ejemplo anterior de la caminata cuesta arriba por las pendientes de grados variables, la imagen de fuerza/fricción sólo describe la dirección y la magnitud de la pendiente descendiente más profunda. Si uno se dirige directamente hacia la pendiente, uno siente toda la fuerza de la fricción (es decir, fricción efectiva = fricción real). Si uno se aleja de la pendiente en forma directa (es decir, se dirige hacia abajo), la fricción se transforma en una fuerza a la máxima potencia posible (es decir, fricción efectiva = 1/(fricción real)). Entre las dos, ocurren valores intermedios. Cuando uno se mueve progresivamente en una dirección alejándose de la fricción máxima, la fricción decrece progresivamente hasta que uno alcanza los 90°. A los 90°, el efecto de la pendiente se neutraliza (fricción efectiva = 1). Entonces, cuando uno se mueve más allá de los 90° hacia la dirección opuesta, las fricciones se vuelven fuerzas que aumentan progresivamente hasta el extremo de los 180°.

Esta variación en la fricción/fuerza efectiva como una función de la dirección aquí se llama función anisotrópica. Con VARCOST, se emplea la siguiente función por defecto:


fricción\_efectiva = fricción\_real<sup>f</sup>

donde  $f = \cos^k \alpha$

y  $k$  = un coeficiente definido por el usuario

y  $\alpha$  = ángulo de diferencia

El ángulo de diferencia en esta fórmula mide el ángulo entre la dirección considerada y la dirección desde la cual están actuando las fricciones (o de manera similar, la dirección *hacia la cual* están actuando las fuerzas). La Figura 23-1 indica la naturaleza de esta función para varios exponentes ( $k$ ) para los ángulos de diferencia de 0 a 90°.



**Figura 23-1**

Observará en la Figura 23-1 que el exponente  $k$  le da a la función una dirección cada vez más específica. En su límite, un exponente extremadamente alto tiene el efecto de hacer que la fricción actúe por completo a 0°, para luego convertirse en una fuerza que actúa en su totalidad a 180°, y para ser neutralizada en todos los demás ángulos. La función anisotrópica por defecto genera valores negativos para todos los ángulos de diferencia de 90° a 270°, sin importar el exponente usado (es decir, los valores negativos de coseno, cuando se los eleva a exponentes impares o pares, generan valores negativos para la función). Entonces, estos ángulos siempre producen valores de fricción efectivos menores que 1 (es decir, actúan como fuerzas).

No suponemos que esta función sea apropiada en todas las circunstancias. Por ello, brindamos la opción de ingresar una función definida por el usuario. El procedimiento para hacer esto es bastante simple – VARCOST tiene la

habilidad para leer un archivo de datos de los valores de función para ángulos de diferencia de 0-360° con incrementos de 0,05°. El formato de este archivo se indica en la descripción del módulo VARCOST dentro del Sistema de Ayuda on-line. Lo más importante para recordar, en cambio, es que con VARCOST, los valores de esa función representan un exponente de la siguiente manera:

$$\text{fricción\_efectiva} = \text{fricción\_real}^f$$

donde  $f$  = una función definida por el usuario.

En el DISPERSE, la misma lógica general se aplica a su operación excepto que la función anisotrópica es diferente:


$$\text{fricción\_efectiva} = \text{fricción\_real} * f$$

$$\text{donde } f = 1/\cos^k \alpha$$

y  $k$  = un coeficiente definido por el usuario

y  $\alpha$  = ángulo de diferencia

El efecto de esta función es modificar las fricciones para que tengan un efecto completo en un ángulo de 0° con aumentos progresivos en la fricción tendiendo al infinito a los 90°. La función está diseñada para que las fricciones efectivas mantengan su tendencia al infinito para todos los ángulos de diferencia mayores que 90°. La Figura 23-2 muestra los valores generados por las funciones por defecto de  $f$ , e ilustra esta diferencia entre las funciones de VARCOST y DISPERSE.



**Figura 23-2**

Al igual que VARCOST, DISPERSE también permite la entrada de una función definida por el usuario. El procedimiento es idéntico, y permite la lectura de un archivo de datos que contiene los valores de función para los ángulos de diferencia de 0-360° con incrementos de 0,05°. El formato de este archivo se indica en la descripción del módulo DISPERSE dentro del Sistema de Ayuda on-line. A diferencia del VARCOST, en cambio, los valores de esa función representan un multiplicador (en lugar de un exponente) de la siguiente manera:

$$\text{fricción\_efectiva} = \text{fricción\_real} * f$$

donde  $f$  = una función definida por el usuario.

## Aplicaciones de VARCOST y DISPERSE

VARCOST y DISPERSE han demostrado ser útiles en una variedad de circunstancias. VARCOST es una extensión directa de la lógica del módulo COST (es decir, como un instrumento para medir los efectos de las fricciones y las fuerzas sobre los costos del movimiento a través del espacio, con la capacidad especial adicional para moderar los efectos de la fricción con varias direcciones de movimiento a través de las celdas). Uno puede usar VARCOST, por ejemplo, junto con ALLOCATE, para asignar distintos pueblos a centros rurales de salud donde los costos del viaje a pie se establecen de acuerdo a los tipos de uso del suelo (fricción isotrópica) y a las pendientes (fricción anisotrópica).

DISPERSE es útil en los casos en que el fenómeno en estudio no posee fuerza motora propia sino que se mueve gracias a fuerzas que actúan sobre éste. Las aplicaciones potenciales pueden incluir estudios de contaminación de fuentes puntuales, modelación del fuego en bosques y pasturas, y posiblemente monitoreo y proyección de derrames de petróleo.

Invitamos a los usuarios a compartir con nosotros sus experiencias en el uso de estos módulos y cómo pueden ser cambiados o ampliados para facilitar dichos estudios. También recibimos funciones anisotrópicas definidas por el usuario que cubran las necesidades de aplicaciones especiales y puedan ser útiles para un grupo más amplio de usuarios.

# CAPÍTULO 24 - Interpolación de Superficies

## Introducción

En SIG, a menudo queremos combinar información de varias capas en los análisis. Si sólo conocemos los valores de una selección de puntos y estos puntos muestrales no coinciden entre las capas, entonces dichos análisis serían imposibles.

Aún cuando los puntos muestrales sí coincidan, a menudo deseamos describir un proceso para *todas* las ubicaciones dentro de un área de estudio, no sólo para los puntos seleccionados. Además, necesitamos superficies completas porque muchos procesos modelados en SIG actúan continuamente sobre una superficie, con el valor de una ubicación dependiente de los valores vecinos.

Cualquier capa SIG, tanto vectorial como raster, que describa *todas* las ubicaciones en un área de estudio es una superficie. No obstante, en el análisis de superficies, nos interesan particularmente esas superficies donde los atributos son cuantitativos y varían continuamente en el espacio. Un Modelo de Elevación Digital raster (DEM), por ejemplo, es dicha superficie. Otros ejemplos de superficies pueden describir el NDVI, la densidad poblacional o la temperatura. En estos tipos de superficies, cada pixel puede tener un valor diferente que el de sus vecinos.

Un mapa de la cobertura terrestre, en cambio, no se considera una superficie de acuerdo con esta definición. Los valores son cualitativos pero no varían continuamente en el mapa. Otro ejemplo de una imagen que no se ajusta a esta definición particular de superficie sería una imagen de la población donde los valores poblacionales son asignados uniformemente a unidades de censo. En este caso, los datos son cuantitativos pero, aún así, no varían continuamente en el espacio. Es más, el cambio en los valores sólo está presente en los bordes de las unidades de censo.

Ninguna capa de superficie SIG puede representar la realidad en toda escala. Por eso, el término *modelo* se utiliza a menudo para referirse a imágenes de superficie. El uso de este término indica una distinción entre la superficie representada digitalmente y la superficie real que el modelo describe. Además indica que pueden existir diferentes modelos para el mismo fenómeno. La elección del modelo a emplear depende de muchas cosas, incluyendo la aplicación, requerimientos y disponibilidad de los datos.

Normalmente resulta imposible medir el valor de un atributo para cada pixel en una imagen. (La excepción es una imagen satelital, la cual mide la reflectancia promedio para cada pixel). A menudo, uno necesita llenar los espacios vacíos entre los puntos de los datos de muestra para crear una superficie completa. Este proceso se denomina interpolación. IDRISI brinda varias opciones para la interpolación que se discuten en este capítulo. Se puede hallar más información acerca de estos módulos en el Sistema de Ayuda on-line.

## Interpolación de Superficies

La elección de la técnica de interpolación depende del tipo de modelo de superficie que Ud. desea producir y de los datos disponibles. En esta sección, las técnicas disponibles en IDRISI están organizadas de acuerdo con el tipo de datos de entrada – puntos o líneas. También se ofrece una descripción del algoritmo usado y de las características generales de las técnicas. Para un tratamiento más teórico de las características de los modelos de superficie producidos por técnicas de interpolación particulares, consulte las referencias citadas al final de este capítulo.

Las técnicas de interpolación se pueden describir como globales o locales. Un interpolador global deriva el modelo de superficie al considerar todos los puntos de datos de una sola vez. La superficie resultante brinda el “mejor ajuste” al conjunto de datos de muestra, pero puede proveer un ajuste muy pobre en ciertas ubicaciones. Un interpolador local, por otra parte, calcula nuevos valores para los pixeles desconocidos al usar los valores de los pixeles conocidos que se encuentran cerca. Los interpoladores pueden definir esa “cercanía” de varias maneras. Muchos le permiten al usuario determinar el tamaño del área y cuántos de los puntos muestrales más cercanos deben considerarse al derivar los valores interpolados.

Las técnicas de interpolación también se clasifican como exactas o inexactas. Una técnica de interpolación exacta siempre conserva los valores originales de los puntos muestrales en la superficie resultante, mientras que un interpolador inexacto puede asignarle nuevos valores a los puntos de datos conocidos.



# Interpolación a partir de Datos Puntuales

## Análisis de Superficies Tendenciales

Las superficies tendenciales son usualmente empleadas para determinar si las tendencias espaciales existen en un grupo de datos y no para crear un modelo de superficie para usar en otros análisis. Las superficies tendenciales también se pueden utilizar para describir y eliminar tendencias amplias de los grupos de datos con el fin de entender mejor influencias más locales. Debido a que la superficie resultante es un modelo matemático ideal, es muy suave y está libre de detalles locales .

En IDRISI, el módulo TREND (Tendencia) se emplea para producir una imagen de superficie tendencial a partir de puntos muestrales. TREND es un interpolador global ya que calcula una superficie que ofrece el mejor ajuste, principalmente para todo el grupo de puntos de datos conocidos. TREND también es un interpolador inexacto. Los valores de los datos en los puntos conocidos se pueden modificar para coincidir con la superficie más adecuada para todo el grupo de datos.

TREND aplica uno de los tres modelos matemáticamente definidos de superficie ideal (lineal, cuadrática o cúbica) al grupo de datos puntuales de entrada. Para visualizar cómo funciona TREND, usaremos un ejemplo de datos de temperatura en varias estaciones climáticas. El modelo de superficie lineal es chato (es decir, un plano). Imagínese los datos de temperatura como puntos que flotan por encima de la parte superior de una mesa. La altura de cada punto sobre la mesa depende de su temperatura. Ahora imagínese un trozo de papel plano ubicado sobre la mesa. Sin doblar el papel en absoluto, uno ajusta la inclinación y la altura del mismo de manera tal que la suma de las distancias entre éste y cada punto sea minimizada. Algunos puntos se encuentran por encima del plano del papel y algunos por debajo. Es más, es posible, en realidad, que ningún punto se encuentre en el papel mismo. Sin embargo, la separación general entre el modelo (el plano) y los puntos muestrales es minimizada. A cada pixel en el área de estudio se le puede asignar entonces la temperatura que corresponde con la altura del papel en esa ubicación de pixel.

El mismo ejemplo se puede utilizar para visualizar los modelos de superficie tendencial cuadrática y cúbica. No obstante, en estos casos, está permitido doblar el papel (pero no arrugarlo). La superficie cuadrática permite la presencia de pliegues amplios en el papel, mientras que la cúbica permite pliegues más complejos aún.

TREND funciona en gran parte como esta analogía exceptuando que una fórmula polinomial que describe el modelo de superficie ideal reemplaza el papel. Esta fórmula se utiliza con el fin de derivar valores para todos los pixeles en la imagen. Además de la superficie interpolada producida, TREND informa (en forma de porcentaje) hasta qué punto el modelo elegido asigna los puntos de entrada. TREND también comunica el cociente-F y los grados de libertad, los cuales pueden ser usados para verificar si la tendencia modelada es significativamente diferente a cero (es decir, ninguna tendencia en absoluto).

## Teselación Thiessen o Voronoi

El término *teselación* significa dividir un área en piezas o mosaicos. Con una teselación Thiessen, el área de estudio se divide en regiones alrededor de los puntos muestrales de manera tal que cada pixel en el área de estudio es asignado al punto de datos más cercano (y toma el valor de él).

Como produce una superficie con mosaicos en lugar de una continua, esta técnica de interpolación es escasamente utilizada para producir modelos de superficie. Comúnmente ésta se usa para identificar las *zonas de influencia* para un grupo de puntos de datos.

Supongamos que un grupo de nuevos centros de salud fuera propuesto para un área rural y sus habitantes necesitaran ser asignados al establecimiento *más cercano*. Si se usara una distancia Euclideana como la definición de *más cercano*, entonces THIESSEN ofrecería el resultado más deseado. Las zonas de influencia basadas en variables más complejas que la distancia Euclideana también se pueden definir en IDRISI usando los módulos COST y ALLOCATE en forma secuencial. En el mismo ejemplo, si el viaje de menor tiempo definiese *más cercano*, y no la distancia euclideana más corta, entonces se usaría COST para desarrollar una superficie de tiempo-viaje (incorporando información acerca de los tipos de caminos, trayectos, etc.) y ALLOCATE para asignar cada pixel a su establecimiento más cercano en términos del viaje de menor tiempo.

## Promedio Ponderado por la Distancia

El promedio ponderado por la distancia preserva los valores de los datos de muestra y, por ello, es una técnica de interpolación exacta. En IDRISI, ésta se encuentra disponible en el módulo INTERPOL.

El usuario puede elegir usar esta técnica como un interpolador tanto global como local. En el caso global, todos los

puntos muestrales se emplean para calcular todos los nuevos valores interpolados. En el caso local, sólo se utilizan en el cálculo los puntos muestrales 4-8 más cercanos al pixel que va a ser interpolado. La opción local es la más recomendada, a menos que los puntos de datos estén distribuidos muy uniformemente y el usuario quiera un resultado más suave.

Con la opción local, se dibuja un círculo definido por un radio de búsqueda alrededor de cada pixel que va a ser interpolado. El radio de búsqueda se establece para producir, en promedio, 6 puntos de control dentro del círculo. Esto se calcula al dividir el área de estudio total por el número de puntos y al determinar un radio que encierre, en promedio, 6 puntos. Sin embargo, este cálculo asume una distribución pareja de los puntos, por lo que se genera algo de flexibilidad. Si se encuentran menos de 4 puntos de control en el área de búsqueda calculada, entonces el radio es expandido hasta que se encuentren al menos 4 puntos. Por otra parte, si se encuentran más de 8 puntos de control en el área de búsqueda calculada, entonces el radio es disminuido hasta que se encuentren como máximo 8 puntos. Debe haber por lo menos 4 puntos disponibles para interpolar cualquier valor nuevo.

Con la implementación de la opción tanto local como global, el usuario puede definir cómo varía la influencia de un punto conocido según la distancia al punto desconocido. La idea consiste en que el atributo de un pixel interpolado debe ser más similar al de su punto de datos conocido más cercano, un poco menos similar al de su próximo punto de datos conocido, y así sucesivamente. Comúnmente, la función empleada es el cuadrado inverso de la distancia ( $1/d^2$ , donde  $d$  es la distancia).

Por cada pixel a ser interpolado, se determina la distancia a todo punto muestral a utilizarse y se computa el cuadrado inverso de la distancia. Cada atributo del punto muestral es multiplicado por su respectiva expresión de las distancias al cuadrado inversas, y todos estos valores son sumados. Esta suma es luego dividida por la suma de las expresiones de las distancias al cuadrado inverso, para generar el valor interpolado.

El usuario puede elegir usar un exponente distinto de 2 en la función. Usar un exponente mayor que 2 hace que la influencia de los puntos muestrales más cercanos tenga relativamente más peso para derivar el nuevo atributo. Usar un exponente de 1 haría que los puntos de datos tengan una influencia más equitativa en el nuevo valor de atributo.

El promedio ponderado por la distancia produce una superficie suave en la que los valores mínimos y máximos ocurren en los puntos muestrales. En las áreas alejadas de los puntos de datos, la superficie tiende a aproximarse al valor promedio local, donde el término *local* es determinado por el radio de búsqueda. La distribución de los puntos de datos conocidos influye en gran medida la utilidad de esta técnica de interpolación. Ésta funciona mejor cuando los datos de muestra son muchos y están distribuidos en forma justa y pareja.

## Modelo Potencial

INTERPOL también ofrece una segunda técnica llamada modelo potencial. Operativamente, ésta es similar al promedio ponderado por la distancia. La diferencia se encuentra en la función empleada. El cálculo es el mismo que el descripto arriba excepto que la suma de los valores de atributo ponderados no es dividida por la suma de los pesos. Esto provoca que los valores en los puntos muestrales a menudo sean más altos que el valor original, especialmente cuando los puntos muestrales están bastante juntos. El método es, por lo tanto, un interpolador inexacto. La superficie parece tener espinas en los puntos muestrales y tiende a aproximarse a cero al alejarse de los puntos muestrales.

Este tipo de método de interpolación está basado en el concepto del *modelo de gravedad* y fue desarrollado para modelar interacciones potenciales entre masas medidas en los puntos muestrales. Por ejemplo, la cantidad de interacción (Ej.: en términos comerciales) entre las personas de dos pueblos está relacionada con el número de personas de cada pueblo y con la distancia a la que se encuentran estos dos pueblos. Cuando hay más personas que se encuentran juntas producen una interacción total mayor. La interacción en un lugar alejado de cualquier pueblo tiende a ser cero. El método del modelo potencial se aplica para fines diferentes a los de los otros métodos discutidos en este capítulo. Éste no se emplearía, por ejemplo, para desarrollar un modelo de superficie a partir de datos de elevación.

## Redes Irregulares Trianguladas

Una Red Irregular Triangulada, o TIN, es una estructura de datos vectoriales. Los puntos muestrales se convierten en los vértices de un grupo de facetas triangulares que cubren por completo el área de estudio. En IDRISI, TIN se genera y luego se emplea para crear un modelo de superficie raster continua. El capítulo **Redes Irregulares Trianguladas y Generación de Superficies** está dedicado a esta serie de procedimientos.

## Kriging y Simulación

Las superficies continuas también se pueden derivar a partir de datos puntuales usando técnicas geoestadísticas. En

IDRISI se ofrecen varias opciones de kriging a través de tres interfases del paquete software Gstat<sup>118</sup>: Modelador de Dependencia Espacial, Ajuste del Modelo y Kriging y Simulación. Al igual que las técnicas ofrecidas en INTERPOL, los métodos kriging pueden emplearse como interpoladores tanto locales como globales. Sin embargo, la implementación local es más utilizada. Kriging preserva los valores de los datos de muestra y es, por lo tanto, un interpolador exacto. La simulación no preserva los valores de los datos de muestra, por lo que resulta un interpolador inexacto.

La diferencia principal entre los métodos kriging y un simple promedio ponderado por la distancia es que los primeros le brindan al usuario gran flexibilidad para definir el modelo a utilizar en la interpolación de un grupo particular de datos.

Estos modelos adaptados son más capaces de representar los cambios en la dependencia espacial dentro del área de estudio. La dependencia espacial es simplemente la idea de que los puntos que se encuentran más juntos poseen valores más similares que los puntos más alejados. Kriging reconoce que esta tendencia de los puntos cercanos a ser más similares no está limitada a una relación de distancia euclideana y puede exhibir muchos patrones diferentes.

El procedimiento kriging genera, además de la superficie interpolada, una segunda imagen de varianza. La imagen de varianza provee, para cada pixel, información acerca de cuán bien se ajusta el valor interpolado al modelo general definido por el usuario. La imagen de varianza, entonces, puede usarse como una herramienta de diagnóstico para perfeccionar el modelo. La meta es desarrollar un modelo con una distribución pareja de la varianza que sea tan cercana a cero como sea posible.

Kriging produce una superficie suave. La simulación, por otra parte, incorpora una variabilidad por pixel en la interpolación y, por ello, produce una superficie rugosa. Usualmente, cientos de dichas superficies son generadas y resumidas para usarse en la modelación de procesos.

Las herramientas geoestadísticas brindadas en las interfases de IDRISI para Gstat se discuten con más detalle en el capítulo **Geoestadística**.

## Interpolación a partir de Datos de Isolíneas

Algunas veces, las superficies son creadas a partir de datos de isolíneas. Una isolínea es una línea de valor igual. Los contornos de elevación son un ejemplo de isolíneas. Las isolíneas rara vez son medidas de campo; comúnmente son el resultado de la digitalización de mapas de papel. Hay que tener en cuenta que los métodos involucrados en la creación de isolíneas pueden tener ya incluido algún tipo de interpolación. La interpolación subsiguiente entre isolíneas agrega otros tipos de errores.

### Interpolación Lineal a partir de Isolíneas

Se encuentra disponible en IDRISI una interpolación lineal entre isolíneas a través del módulo INTERPOL. Las isolíneas primero deben ser rasterizados, con los atributos de los pixeles que representan isolíneas iguales al valor de la isolínea. También es posible agregar puntos de valor conocido antes de la interpolación. Tal vez sea más útil, sin embargo, agregar líneas que definan bordes, crestas de sierras u otras características de ruptura similares no descriptas por el grupo original de datos de isolíneas.

En la interpolación, se dibujan cuatro líneas a través de un pixel que será interpolado, como se muestra en la Figura 24-1. Las líneas se extienden hasta que interceptan un pixel de valor conocido en cada dirección. La pendiente a lo largo de cada una de las cuatro líneas se calcula usando los atributos de los pixeles interceptados y sus coordenadas X e Y (la pendiente es simplemente el cambio en el atributo de un extremo de la línea al otro, dividido por el largo de la línea). La línea con la mayor pendiente se elige para interpolarse el valor del pixel desconocido.<sup>119</sup> El valor en la ubicación del pixel que va a ser interpolado se calcula basándose en los valores de atributo de los pixeles interceptados, en la pendiente de la línea y en la posición de X e Y del pixel que va a ser interpolado. Este proceso se lleva a cabo con todos los pixeles desconocidos.




Figura 24-1

<sup>118</sup> Gstat, © Edzer Pebesma, tiene una licencia de uso libre disponible en GNU. Ver el Sistema de Ayuda on-line para más detalles.

<sup>119</sup> La línea con mayor pendiente se usa para evitar las líneas planas que aparecen cuando una línea intercepta la misma isolínea en ambos extremos. Esto es bastante común con los mapas topográficos y puede conducir a una abundancia de áreas planas en la superficie interpolada.

La elección de la resolución cuando las isolíneas son rasterizadas es crucial. Si la resolución es demasiado gruesa, se puede rasterizar más de una línea en un solo pixel. En este caso, sólo se retiene el último valor y el resultado es una interpolación pobre. Se recomienda establecer una resolución inicial que sea igual a o menor que la distancia entre las isolíneas más cercanas. Una superficie de resolución más gruesa se puede generar luego de la interpolación inicial usando RESAMPLE o CONTRACT. Tenga en cuenta que se puede producir con facilidad una superficie con más detalles aparentes que los que están presentes en realidad en los datos de isolíneas. Del Barrio y otros (1992) presentan un método cuantitativo para determinar una resolución que capture el nivel de información óptimo posible dadas las características de los datos de isolíneas de entrada.

La interpolación lineal a partir de isolíneas puede producir algunos artefactos obvios y no deseados en la superficie resultante. Un histograma de una superficie producida por esta técnica de interpolación suele mostrar una forma “ondulada”, con picos de histograma ubicados en los valores de las isolíneas de entrada. Además, algunos artefactos con forma de estrella pueden estar presentes, particularmente en los picos de la superficie. Estas características pueden ser mitigadas en cierto grado (aunque no eliminadas) con la aplicación de un filtro de media (usando el módulo FILTER).

Finalmente, las cimas de las colinas y las bases de los valles son aplanadas con el valor del contorno circundante. En muchos casos, si hay datos de isolíneas disponibles, el limitado pero optimizado método TIN que se describe a continuación produce un modelo de superficie mejor.

INTERCON es un interpolador exacto ya que las isolíneas retienen sus valores. También se lo puede llamar un interpolador local, aunque las isolíneas usados para interpolar cualquier pixel pueden estar bastante distantes de ese pixel.

## Redes Irregulares Trianguladas Limitadas

Como se expresó antes, las redes irregulares trianguladas puede generarse a partir de datos puntuales. Además, el módulo TIN de IDRISI permite la entrada de datos de isolíneas para la creación de TINs. Al hacer esto, la red se puede limitar para que ningún borde de faceta triangular cruce una isolínea. Esto fuerza la triangulación a preservar el carácter de la superficie como la definen las isolíneas. Una TIN desarrollada a partir de isolíneas también puede ser optimizada para modelar mejor características tales como las cimas de las colinas y las bases de los valles. Una vez que se ha desarrollado la red, ésta se puede utilizar para generar un modelo de superficie raster con el módulo TINSURF.

Todos los pasos involucrados en este proceso se detallan en el capítulo **Redes Irregulares Trianguladas y Generación de Superficies**.

## Eligiendo un Modelo de Superficie

Ningún método de generación de superficies es mejor que otro en forma abstracta. El mérito relativo de cualquier método depende de las características de los datos muestra de entrada y del contexto en el cual se va a usar el modelo de superficie. La precisión de las medidas de los puntos muestrales, así como también la frecuencia y la distribución de los puntos muestrales relativas a la escala de variación necesaria, influyen en la elección de la técnica de interpolación que se va a aplicar a esos datos. Además, la escala de los procesos a modelar es clave para guiar la creación de un modelo de superficie interpolada. La forma de la superficie (Ej.: convexa, cóncava) y el nivel de variación local son a menudo aspectos claves de los modelos de procesos, donde el valor o los eventos de un pixel influyen aquellos de los pixeles vecinos. Es común desarrollar varios modelos de superficie y emplear uno por vez para determinar la sensibilidad de un análisis al tipo de técnicas de generación de superficies usado.

## Referencias / Lectura Complementaria

Blaszczynski, J., 1997. Landform Characterization With Geographic Information Systems, *Photogrammetric Engineering and Remote Sensing*, 63(2): 183-191.

Burrough, P., and McDonnell, R., 1998. *Principles of Geographical Information Systems*, 98-161, Oxford University Press, Londres.

Del Barrio, G., Bernardo, A., y Diez, C., 1992. The Choice of Cell Size in Digital Terrain Models: An Objective Method, Conference on Methods of Hydrologic Comparison, Oxford, Reino Unido, del 29 de septiembre al 20 de octubre.


Desmet, J., 1997. Effects of Interpolation Errors on the Analysis of DEMs, *Earth Surface Processes and Landforms*, 22: 563- 580.

Lam, N., 1983. Spatial Interpolation Methods: A Review, *The American Cartographer*, 10(2): 129-149.

# CAPÍTULO 25 - Generación de Superficies y Redes Irregulares Trianguladas


## Introducción

Las Redes Irregulares Trianguladas (TINs) son la estructura más comúnmente usada para modelar superficies continuas con un modelo de datos vectoriales. También son importantes para los sistemas raster porque pueden usarse para generar modelos de superficies raster como los Modelos de Elevación Digital (DEMs). Con la triangulación, los puntos de datos con valores de atributo conocidos (Ej.: elevación) son usados como los vértices (es decir, los puntos de las esquinas) de un grupo de triángulos generado. El resultado es una teselación triangular de toda el área que se encuentra dentro del límite exterior de los puntos de datos (conocido como el *casco convexo*). La Figura 25-1 ilustra una triangulación realizada con un grupo de puntos de datos.



**Figura 25-1.** Un juego de puntos de datos (izq.) y una triangulación de esos puntos (derecha).

Existen varios métodos diferentes de triangulación. El proceso de triangulación Delaunay es comúnmente utilizado en la modelación de TINs y es el empleado en IDRISI. Una triangulación Delaunay está definida por tres criterios: 1) un círculo que pasa por los tres puntos de cualquier triángulo, no contiene otro punto de datos en su interior, 2) ningún triángulo se superpone, y 3) no hay vacíos en la superficie triangulada. La Figura 25-2 muestra ejemplos de una triangulación Delaunay y una de otro tipo.



**Figura 25-2.** Triangulación de Delaunay (izq.) y triangulación no-Delaunay (derecha).  
El triángulo sombreado no reúne el criterio del círculo vacío.

Un resultado natural del proceso de triangulación Delaunay es que el ángulo mínimo en cualquier triángulo es maximizado. Esta propiedad es usada por el algoritmo de IDRISI en la construcción de TINs. El número de triángulos ( $N_t$ ) que conforma una TIN Delaunay es  $N_t = 2(N-1) - N_h$  y el número de bordes ( $N_e$ ) es  $N_e = 3(N-1) - N_h$ , donde  $N$  es el número de puntos de datos, y  $N_h$  es el número de puntos en el casco convexo.

IDRISI incluye opciones para usar datos de puntos verdaderos o puntos de vértices extraídos de las isolíneas<sup>120</sup> como entrada para la generación de TINs. El módulo TIN también ofrece opciones para usar triangulaciones no limitadas o limitadas, para optimizar la red al eliminar los bordes de “túnel” y “puente”, y para generar una superficie raster a partir de la red aplicando el módulo TINSURF. También hay módulos disponibles para preparar datos de entrada TIN. Estos se exponen más abajo

En IDRISI, la estructura del archivo TIN consiste en un archivo de línea vectorial (que contiene los bordes del triángulo) y en un archivo ASCII TIN asociado (que contiene información que indica qué puntos conforman cada triángulo). Los detalles sobre la estructura del archivo pueden encontrarse en el Sistema de Ayuda on-line.

## Preparando los Datos de Entrada TIN

### Puntos

Normalmente, la preparación de datos necesaria es mínima cuando se usan datos puntuales para crear una TIN. En algunos casos se prefiere reducir el número de puntos que va a emplearse en la triangulación. Por ejemplo, si el número y la densidad de los puntos exceden la exactitud requerida de la red, el usuario puede optar por eliminar puntos ya que una cantidad menor de puntos permite un procesamiento de la red más veloz. El módulo GENERALIZATION ofrece esta capacidad de reducción de puntos.

Si se utilizan datos puntuales como entrada para la generación de TIN, sólo está disponible la opción de triangulación no limitada que se describe más adelante. Si se utilizan datos de isolíneas como entrada para la generación de TINs, tanto la opción no limitada como la limitada se encuentran disponibles y se puede esperar un mejor resultado de la red. Si el producto final deseado de los datos puntuales de entrada es una superficie raster, el módulo INTERPOL y las interfaces para Gstat de IDRISI ofrecen alternativas para TIN/TINSURF. (Vea los capítulos **Análisis de Superficies y Geoestadística**.)

### Líneas

Cuando se utiliza un archivo de isolíneas como entrada para una TIN, solo los vértices<sup>121</sup> que forman las líneas se usan en la triangulación. Puede resultar útil examinar la densidad de los vértices en el archivo de isolíneas antes de generar la red.

El módulo GENERALIZATION se puede emplear para extraer los vértices de un archivo de línea para usarlos en un archivo vectorial de puntos para la visualización.

Puede ser preferible agregar puntos en las líneas si los puntos están tan separados que crean largos segmentos de líneas rectas que resultan en grandes facetas TIN. A veces, también se prefiere la reducción de la cantidad de puntos de las líneas, particularmente con los datos de isolíneas que fueron digitalizados en modo de flujo. En este caso, el número de puntos en las líneas puede ser mucho mayor que el necesario para la resolución deseada de la red, y solo servirá para reducir la velocidad del proceso de generación de TINs. El módulo TINPREP realiza la adición o reducción de puntos en las líneas. Hay otras opciones de generalización de líneas también disponibles en el módulo GENERALIZATION.

Si se usan datos lineales para crear TINs, se encuentran disponibles tanto la triangulación no limitada como la limitada. Las diferencias entre estas opciones se describen abajo. Si una superficie raster es la producción final deseada de los datos de isolíneas de entrada, el módulo INTERCON ofrece una alternativa ante TIN/TINSURF. Sin embargo, este último normalmente produce un resultado superior.

## Resumen de Comandos

A continuación se halla una lista y una breve descripción de los módulos mencionados en esta sección.

---

<sup>120</sup> En este capítulo, el término isolínea se refiere a cualquier línea que represente un valor de atributo constante. Los contornos de elevación son un ejemplo de isolíneas.

<sup>121</sup> En este contexto, el término “vértices” se refiere a todos los puntos que forman una línea, incluyendo los puntos iniciales y finales.

GENERALIZATION reduce o “generaliza” datos vectoriales de puntos, extrae los vértices (puntos) de un archivo vectorial lineal para colocarlos en un archivo vectorial de puntos, y generaliza datos vectoriales lineales.

INTERPOL interpola una superficie raster a partir de datos de puntos. Las interfases para Gstat de IDRISI brindan herramientas geoestadísticas que pueden emplearse para crear una superficie raster a partir de datos de puntos.

TINPREP agrega o reduce vértices en las líneas vectoriales.

INTERCON interpola una superficie raster a partir de datos de isolíneas rasterizados.

TIN crea una TIN a partir de datos vectoriales de puntos o lineales. TINSURF puede aplicarse automáticamente desde el diálogo de TIN si se desea como salida una superficie raster.

TINSURF crea una superficie raster a partir de una red existente.


## TINs No Limitadas y Limitadas

La triangulación Delaunay no limitada está explicada en la sección Introducción de este capítulo, y se implementa por el módulo TIN de IDRISI por medio de un algoritmo diseñado para acelerar el procesamiento. Primero, el grupo de puntos de entrada (o vértices de isolíneas) se dividen en secciones. Luego cada una de las secciones se triangula. Las “mini-TINs” resultantes son combinadas. Siempre se implementa un procedimiento de optimización local durante el proceso de combinación para maximizar los ángulos mínimos y así satisfacer el criterio Delaunay para la triangulación.

Una triangulación Delaunay limitada es una extensión de la triangulación no limitada descrita arriba, con algunas condiciones adicionales aplicadas en la selección de los vértices de los triángulos. En IDRISI, la triangulación Delaunay limitada utiliza las isolíneas como límites de ruptura de línea que no se pueden cruzar para controlar el proceso de triangulación. Este proceso asegura que los bordes de los triángulos no crucen las isolíneas y que el modelo TIN resultante sea consistente con los datos de isolíneas originales. No todos los triángulos cumplen necesariamente con los criterios Delaunay cuando se usa la triangulación limitada.

En IDRISI, la TIN limitada es creada en un proceso de dos pasos. Primero, se completa una triangulación no limitada. Luego se verifican los bordes del triángulo para detectar intersecciones de isolíneas.

Cuando dicha intersección es encontrada, se ejecuta nuevamente una rutina de optimización local hasta que no quede ninguna intersección de isolíneas. La Figura 25-3 muestra TINs limitadas y no limitadas creadas a partir del mismo grupo de puntos de datos de vértices de isolíneas.



**Figura 25-3.** Triangulación de Delaunay no limitada (izq.) limitada (derecha)  
Las líneas solidas representan isolíneas.

## Eliminando Bordes “Puente” y “Túnel” de las TINs

En la Figura 25-4a se muestran líneas de contorno en la cima de una colina. En la Figura 25-4b, el contorno más alto se muestra junto con los triángulos resultantes creados dentro del mismo cuando se genera una TIN limitada. Como los tres puntos para todos los triángulos tienen la misma elevación, la cima de la colina es perfectamente chata en el modelo TIN.




Nuestra experiencia con el terreno real nos demuestra que la verdadera superficie probablemente no sea chata sino que se eleva por encima de las facetas TIN. Los bordes de las facetas TIN que se encuentran por debajo de la superficie verdadera en este caso son ejemplos de lo que llamamos “bordes túnel”. Estos son identificados en la Figura 25-4b. Un borde túnel es cualquier borde de un triángulo que se encuentra debajo de la superficie verdadera. De manera similar, si los contornos de la Figura 25-4a representaran la base de un valle o una depresión, las facetas TIN de la Figura 25-4b describirían una superficie plana más alta que la superficie real. Los bordes de las facetas TIN que se hallan por encima de la superficie verdadera se llaman “bordes puente”.


Los bordes puente y túnel (P/T) no están limitados a las cimas de colinas o a las bases de depresiones. También pueden ocurrir en pendientes, particularmente donde las isolíneas son onduladas, y en crestas de montañas o canales. Dos de estos ejemplos se muestran en la Figura 25-5.

Para optimizar una TIN, se pueden eliminar los bordes P/T. La eliminación de estos bordes técnicamente se podría realizar en una TIN no limitada, pero esto no se recomienda y no está permitido en IDRISI. Una TIN óptima se logra si se emplean isolíneas como la entrada original para la generación de TINs, si se usa la triangulación limitada y se eliminan los bordes P/T.

Mientras que muchos de los conceptos de esta sección están ilustrados con datos de elevación, los procedimientos no se limitan a estos datos.



**Figura 25-4 a.** Contornos en la cima de una colina; b: triangulación del contorno mas alto, con los bordes B/T identificados; c: colocación de los puntos críticos sobre los bordes B/T.



**Figura 25-5 a.** Contornos en un arroyo; b: contornos en una característica “silla de montar”. Los contornos se muestran con líneas sólidas, los bordes de los triangulos limitados, con líneas de puntos. Los bordes B/T se muestran con líneas rojas.

## Eliminación de los Bordes Puente y Túnel y Ajuste de las TINs

El módulo TIN de IDRISI incluye una opción para crear una red con todos los bordes P/T eliminados. Esta opción sólo está disponible si utilizan datos de isolíneas y la opción de triangulación limitada. Primero, se crea una TIN normal a partir de los datos de entrada vectoriales. Luego, se identifican todos los bordes P/T en la red. En IDRISI,

un borde P/T es identificado como cualquier borde de un triángulo con los puntos finales del mismo atributo, donde estos puntos finales no son puntos vecinos en una isolínea.

Los nuevos puntos, denominados *puntos críticos*, son creados en los puntos medios de los bordes P/T (Figura 25-4c). Las áreas alrededor de los puntos críticos luego son re-trianguladas (Figura 25-4d). Cuando un borde P/T es compartido por dos triángulos, se generan entonces cuatro triángulos nuevos. Cuando un borde P/T es parte del límite de la red, y por lo tanto es usado por un solo triángulo, se generan dos nuevos triángulos.

Una vez que los puntos críticos han sido colocados y la triangulación ha sido ajustada, el próximo paso es asignar valores de atributo apropiados (Ej.: elevaciones) a estos nuevos puntos.

## Interpolación de Atributos para los Puntos Críticos

En IDRISI, el método recomendado para la determinación del atributo de un punto crítico usa una forma parabólica. Se eligió la parábola, al igual que un método polinomial no lineal de segundo orden, porque combina la simplicidad computacional con una forma que es compatible con la mayoría de las superficies topográficas.<sup>122</sup> Antes de describir los detalles matemáticos y el algoritmo del cálculo de los valores de los puntos críticos, usaremos una ilustración para considerar la lógica general.

### Lógica General

Supongamos que los contornos de la Figura 25-4a describen una colina y que la cima de la colina más allá del contorno más alto tiene un pico redondeado. De esta forma, podemos imaginar la colocación de una superficie parabólica (como un recipiente con forma de U invertida) en la cima de la colina. La superficie parabólica particular que vamos a elegir depende de la forma del terreno circundante. Si las pendientes fueran suaves y se dirigiesen al contorno más alto, entonces elegiríamos una superficie con pendientes de lados bajos y una cima ancha. Pero si las pendientes fueran profundas, elegiríamos una superficie con lados más verticales y una cima más angosta. Una vez que se ha elegido una superficie en particular, todos los puntos críticos en los bordes túnel de la cima de la colina pueden ser proyectados en una superficie parabólica. A estos puntos luego se les puede asignar la elevación de la superficie de su ubicación.

La implementación real de la interpolación difiere de la lógica general descrita arriba en que se usan parábolas bidimensionales en lugar de superficies parabólicas. Hasta ocho parábolas, correspondientes con ocho direcciones, se colocan en cada ubicación de los puntos críticos. Se deriva por cada parábola un atributo para el punto crítico, y el valor de atributo final asignado al punto es su promedio. A continuación se brindan los detalles del proceso.

### Calculando el Atributo de los Puntos Críticos


Una parábola es definida por la siguiente ecuación:

$$(X-a)^2 = 2p(Y-b)$$

Donde el punto (a, b) define el punto central (cima o base) de la parábola y el parámetro p define la profundidad de la forma. Cuando p es positivo, la parábola tiene forma de U. Cuando p es negativo, la parábola está invertida. Mientras más grande sea el valor absoluto de p, más ancha será la parábola. La Figura 25-6 muestra varias parábolas y sus ecuaciones.

---

<sup>122</sup> Aunque el algoritmo parabólico es el recomendado, las opciones lineal y lineal optimizada también están disponibles en el módulo TIN como métodos de interpolación de puntos críticos. En el ejemplo de la cima de la colina, un pico puntiagudo se modelaría por medio del método lineal en contraste con el pico redondeado del método parabólico. El método lineal optimizado usa una interpolación lineal a menos que las pendientes en las ocho direcciones (vea la discusión de la interpolación parabólica) sean cero, en cuyo caso éste emplea la opción parabólica.




**Figure 25-6.** Ejemplos de parábolas y sus ecuaciones.  
A la izquierda,  $p$  es negativa. A la derecha,  $p$  es positiva.

Para traducir la ecuación parabólica general al problema de la interpolación del atributo del punto crítico, renombramos los ejes  $X$  y  $Y$  de la Figura 25-6 como  $S$  y  $H$ , donde  $S$  representa la distancia desde el origen ( $o$ ) y  $H$  representa el valor de atributo (Ej.: elevación) del origen ( $o$ ). (El origen es definido por la ubicación y el atributo del punto original como se describe abajo).

En el ejemplo de un punto crítico sobre un borde túnel en la cima de una colina, el plano de la parábola es un corte transversal de la colina.

Para definir una parábola para un punto crítico, deben encontrarse tres puntos con coordenadas conocidas y atributos que se hallen en la misma parábola.<sup>123</sup> Se desarrollan hasta ocho parábolas, cada una definida por tres puntos, para cada punto crítico.

Para cada punto crítico, se lleva a cabo un proceso de búsqueda para encontrar intersecciones con isolíneas en cada una de las ocho direcciones, como se ilustra en la Figura 25-7a. Si se hallan dos intersecciones por dirección, entonces se pueden definir ocho parábolas. Cada una está definida por tres puntos, con dos puntos tomados de una dirección del punto crítico y el otro tomado de la dirección opuesta. En la Figura 25-7b, los puntos de intersección para una dirección de búsqueda, puntos  $P_0$ ,  $P_1$  y  $P_2$ , son utilizados para definir la parábola que se muestra en la Figura 25-7c. El punto que se halla entre dos intersecciones del punto crítico siempre se llama *punto original* y se lo nombra  $P_0$ . Este punto se establece en  $S=0$ , entonces las distancias ( $S$ ) a todos los demás puntos son medidas desde este punto original.  $P_1$  se encuentra entre el punto crítico y el punto original, y  $P_2$  se halla en el lado opuesto del punto crítico.



**Figura 25-7 a.** Búsqueda de ocho direcciones para las intersecciones de isolíneas para un punto crítico; **b:** Puntos de intersección para una dirección; **c:** Parábola derivada de puntos de intersección. El atributo ( $H_p$ ) para el punto crítico se puede encontrar con la distancia del punto crítico ( $S_p$ ) o desde  $P$ .

<sup>123</sup> Cualquier parábola puede ser definida una vez que se conocen los tres puntos sobre ésta. Se pueden escribir tres ecuaciones (una por cada punto) como se muestran abajo. Para cada una, se conoce la distancia ( $S$ ) desde ese punto al origen y también el atributo ( $H$ ). estas ecuaciones simultáneas se pueden resolver entonces para  $a$ ,  $b$  y  $p$ .  
 $(S_0 - a)^2 = 2p(H_0 - b)$        $(S_1 - a)^2 = 2p(H_1 - b)$        $(S_2 - a)^2 = 2p(H_2 - b)$

Si no se encuentran tres intersecciones para una parábola particular (Ej.: en el borde de una cobertura), entonces ésta permanece sin definir y el número de parábolas usadas para interpolar el valor de atributo del punto crítico será menor que ocho.

Para cada parábola definida, el valor de atributo de cualquier punto en la parábola se puede hallar al ingresar en la ecuación parabólica su distancia hasta el punto original. La siguiente ecuación puede usarse para calcular el atributo de un punto crítico para una de sus parábolas:<sup>124</sup>

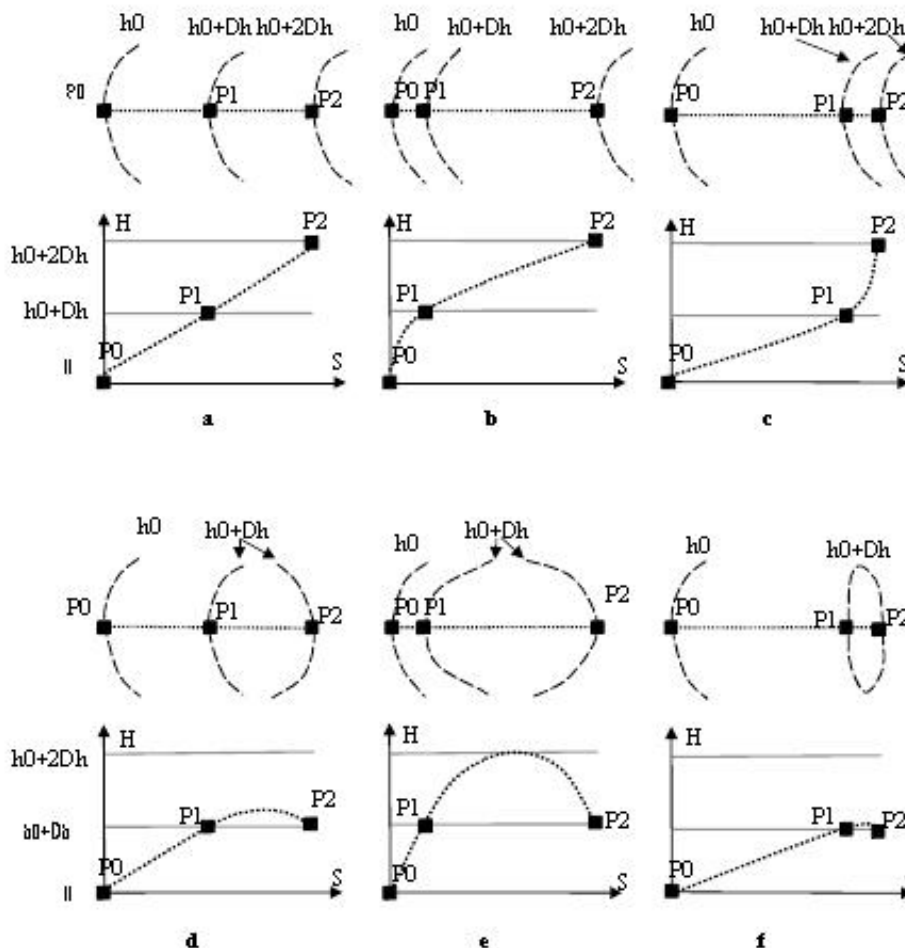
$$H = \sum_{i=0}^2 h_i \cdot \prod_{j=0, j \neq i}^2 \left[ \frac{(S_{\text{point}} - S_j)}{(S_i - S_j)} \right]$$

Donde  $h_i$   $i = 0, 1, 2$  son valores de atributo de los tres puntos de intersección,  $P_0, P_1$  y  $P_2$ ;  $S_i$ ,  $i, j = 0, 1, 2$  representan las distancias desde el punto original hasta los puntos de intersección, y  $S_{\text{point}}$  representa la distancia desde el punto original hasta el punto crítico. Según las definiciones anteriores de los puntos de intersección (Figura 25-6b), sabemos que  $S_0 = 0$ , mientras que  $S_1 = P_1 P_0$ , y  $S_2 = P_2 P_0$ .

Para cada parábola, el valor de atributo en la posición del punto crítico se calcula de esta manera. El valor de atributo final que es asignado al punto crítico es el promedio de todos los valores interpolados válidos (los casos no válidos se discuten a continuación).

La Figura 25-8 muestra varios ejemplos de casos en los que los bordes P/T pueden ser definidos y un nuevo valor para los puntos críticos colocado sobre sus puntos medios puede ser interpolado. En cada figura, sólo se ilustra una dirección de búsqueda. Las Figuras 25-8 a, b y c son ejemplos de casos donde los puntos críticos ocurren en las pendientes mientras que las figuras 25-8 d, e y f son casos donde los puntos críticos ocurren en las cimas de colinas. Para los casos en que el valor de atributo del punto crítico es menor que los de las isolíneas circundantes, las curvas están invertidas.

<sup>124</sup> La ecuación incorpora la derivación de los parámetros parabólicos  $a$ ,  $b$  y  $p$ .



**Figura 25-8.** Seis ejemplos de interpolación parabólica de puntos críticos. La parte superior de cada ejemplo ilustra la vista de mapa de las isolíneas y los puntos de intersección (P0, P1 y P2) para una dirección de búsqueda (línea de puntos) de un punto crítico. La parte inferior muestra la parábola para ese grupo de puntos de intersección. El atributo para el punto crítico (que siempre se encuentra entre P1 y P2) puede hallarse marcando el punto crítico sobre la curva parabólica en su distancia (S) desde P0.

## Casos No Válidos

Existen dos circunstancias extremas en las cuales el procedimiento de interpolación parabólica no es válido:

1. Si los tres puntos de intersección tienen el mismo valor de atributo, ninguno de los tres puntos es usado en la interpolación. Un valor interpolado para el punto crítico no es calculado entonces para esta dirección. El valor de atributo asignado sería un promedio de los otros valores interpolados.
2. Si el valor interpolado es mayor que (en el caso de los bordes túnel) o menor que (en el caso de los bordes puente) el valor del próximo contorno supuesto, entonces al punto crítico se le asigna el valor del próximo contorno supuesto.<sup>125</sup> La naturaleza de los mapas de contornos requiere dicha limitación.

## Productos de TIN

Los productos del módulo TIN consiste en un archivo vectorial lineal que define los bordes de los triángulos, un archivo ASCII .TIN que contiene la información topográfica para la triangulación y, si se aplicó la eliminación de los bordes P/T, un archivo vectorial de puntos de los puntos críticos que fueron agregados. Todas estas piezas excepto el archivo vectorial de bordes de

<sup>125</sup> El algoritmo usa el intervalo de contorno local para cada punto crítico para que los datos de isolíneas con intervalos de contorno variables no presenten problemas.

triángulos, además del archivo vectorial de datos original, son usadas por el módulo TINSURF para crear una superficie raster a partir de la TIN.

## Generando una Superficie Raster a partir de una TIN

Una superficie raster puede ser generada de la red TIN mientras ésta es creada o puede ser generada más tarde a partir de un archivo TIN existente. El módulo TINSURF crea la superficie raster. Su diálogo sólo pide como entrada el archivo TIN. Sin embargo, el archivo TIN almacena el nombre del archivo vectorial original usado para crear la red y también tiene información sobre si se ha aplicado la eliminación de los bordes P/T. Si la red es el resultado de la eliminación de los bordes P/T, entonces TINSURF también requiere el archivo vectorial del punto crítico. Por lo tanto Ud. no debe borrar, mover o renombrar ninguno de estos archivos antes de crear la superficie raster.

Para cada pixel raster en la imagen de salida se calcula un valor de atributo. Este cálculo se basa en las posiciones y atributos de los tres puntos de vértices de la faceta triangular dentro de la cual se encuentra el centro del pixel y la posición del centro del pixel.<sup>126</sup> La lógica es la siguiente:

1. Resuelva la siguiente serie de ecuaciones simultáneas para A, B y C:

$$H_1 = Ax_1 + By_1 + C$$

$$H_2 = Ax_2 + By_2 + C$$

$$H_3 = Ax_3 + By_3 + C$$

Donde  $H_{1,2,3}$  son los valores de atributo (Ej.: elevaciones) de los tres vértices de la faceta triangular y  $(x,y)_{1,2,3}$  son sus coordenadas del sistema de referencia.

2. Dadas A, B y C, como se derivaron arriba, resuelva lo siguiente para  $H_p$ :

$$H_p = Ax_p + By_p + C$$

Donde  $H_p$  es el atributo del pixel y  $(x,y)_p$  es la coordenada del sistema de referencia del centro del pixel.

3. Asígnele al pixel el valor de atributo  $H_p$ .

El algoritmo procede sobre una base de faceta por faceta, de manera tal que la derivación de A, B y C en el paso 1 se lleva a cabo solo una vez para todos los pixeles que se hallan dentro de una sola faceta.

## Optimización de las Superficies Raster

Para la generación óptima de una superficie raster a partir de un modelo TIN, se debe prestar atención a la preparación de los datos usados para crear la red TIN. Si se usan datos de isolíneas, las isolíneas no deben cruzarse. La distribución de los puntos en el archivo vectorial de entrada debe evaluarse visualmente y ajustarse, si es necesario, reduciendo o agregando puntos. Si hay valores de atributo de puntos disponibles en los picos y valles del área de estudio, la incorporación de éstos a los datos de entrada reducirá los efectos de los bordes túnel y puente y mejorará la calidad de la red TIN resultante y de la siguiente superficie raster.

Una red TIN sólo cubre el área dentro del casco convexo de los puntos de datos. Esto puede presentar un problema si los datos vectoriales originales no cubren toda el área de estudio. Las áreas fuera del casco convexo no serán cubiertas por triángulos en la red y se les asignará un valor de fondo en la superficie raster resultante. Una opción para agregar puntos de esquina está disponible en el diálogo de TIN para ayudar a mitigar este problema de las esquinas de la imagen.

No obstante, pueden existir áreas fuera del casco convexo aún cuando se han agregado puntos de esquinas. Si es posible, se recomienda que los datos vectoriales de punto o isolíneas usados para crear la red se extiendan más allá de los límites del área de estudio deseada. Luego especifique las coordenadas raster delimitantes finales en

---

<sup>126</sup> Cada centro de pixel se encuentra en una sola faceta TIN, pero una sola faceta puede contener varios puntos de centros de pixel.

TINSURF. Esto producirá una TIN que cubre toda el área de estudio rectangular y una superficie raster que no contiene valores de fondo.

## Lectura Complementaria

Lee J., 1991. Comparison of Existing Methods for Building Triangular Irregular Network Models of Terrain From Grid Digital Elevation Models, *International Journal of Geographic Information Systems*, 3: 267-285.

Tsai, V. J. D., 1993. Delaunay Triangulations in TIN Creation: an Overview and a Linear-time Algorithm, *International Journal of Geographic Information Systems*, 6: 501-512.

Zhu, H., Eastman, J. R., y Schneider, K., 1999. Constrained Delaunay Triangulation and TIN Optimization Using Contour Data, *Proceedings of the Thirteenth International Conference on Applied Geologic Remote Sensing*, 2: 373-380, Vancouver, British Columbia, Canadá.

# CAPÍTULO 26 - Geoestadística

## Introducción

La geoestadística brinda herramientas para la exploración y caracterización estadística de datos puntuales de muestra.

También provee un número de técnicas para la interpolación de superficies a partir de dichos datos. El *kriging ordinario* es la más conocida. Mientras que las técnicas se originaron con científicos que trabajan en la industria minera, se ha encontrado una audiencia más amplia en esos campos en los cuales tanto los valores de datos como sus ubicaciones se consideran analíticamente importantes.

Varias técnicas de interpolación fueron introducidas en el capítulo **Interpolación de Superficies**. Las técnicas geoestadísticas se distinguen de éstas porque le proporcionan a los analistas de SIG la habilidad para incorporar información acerca de los patrones de continuidad espacial en el modelo de interpolación y también para producir superficies que incluyen artefactos de variación local. Los métodos permiten un alto grado de flexibilidad para el usuario en la detección y definición de estructuras que describen la naturaleza de un grupo de datos. Es más, se puede ensamblar un grupo de estructuras, cada una de las cuales describe un aspecto del grupo de datos.

Con esta flexibilidad, sin embargo, también se genera cierto riesgo. Del mismo grupo de datos, es posible producir muchas superficies – todas son muy diferentes, y todas son representaciones similarmente razonables de la realidad. Se le aconseja al nuevo usuario iniciarse en la geoestadística de forma deliberada y con cierta precaución. El entendimiento y el respeto por las suposiciones subyacentes de estas técnicas son esenciales si los resultados deben brindar información significativa para cualquier análisis.

Este capítulo presenta un breve resumen de las capacidades geoestadísticas ofrecidas por medio de las interfaces para Gstat de IDRISI.<sup>127</sup> Para tratamientos más completos y teóricos de la geoestadística, consulte las referencias expuestas al final de este capítulo. El **Tutorial** incluye un extenso ejercicio que ilustra el uso de las herramientas geoestadísticas disponibles en IDRISI.

## Continuidad Espacial

La noción subyacente que alimenta los métodos geoestadísticos es bastante simple. En los fenómenos que varían continuamente (Ej.: elevaciones, lluvia), es más probable que los lugares que se encuentran más cerca tengan valores más similares que aquellos que se encuentran alejados. En geografía, esta tendencia a ser más similar a los vecinos más cercanos es cuantificada por medio de medidas de autocorrelación y continuidad espaciales. En la geoestadística, la variabilidad, el complemento de la continuidad, es más a menudo el centro del análisis.

La primera tarea al usar las técnicas geoestadísticas para crear superficies es describir de manera tan completa como sea posible, la naturaleza de la variabilidad espacial presente en los datos de muestra. La variabilidad espacial es determinada en términos de distancia y dirección. El análisis se realiza en pares de puntos muestrales. Cada punto de datos es colocado en pares con cada uno de los otros puntos de datos. Cada par puede ser caracterizado por su *distancia de separación* (la distancia euclideana entre los dos puntos) y su *dirección de separación* (el acimut en grados de la dirección de un punto al otro).<sup>128</sup> El grupo de puntos muestrales en la Figura 23-1 puede producir pares caracterizados como se muestra en la Tabla 23-1.

La medida de la distancia es usualmente representada en unidades de *intervalos*, donde la longitud de un intervalo (es decir, la distancia o demora de un intervalo) es establecida por el usuario. Al especificar un intervalo particular durante el análisis, el usuario está limitando los pares considerados en aquellos dentro de un rango de distancias definidas por el intervalo. Si el intervalo fuera definido en 20 metros, por ejemplo, un análisis de los datos en el tercer intervalo incluiría sólo esos pares de datos con distancias de separación de 40 a 60 metros.

---

<sup>127</sup> IDRISI brinda una interfase de usuario gráfica para Gstat, un programa para la modelación geoestadística, la predicción y la simulación escrito por Edzer J. Pebesma (Facultad de Geografía Física, Universidad de Utrecht). Gstat se encuentra libremente disponible bajo la Licencia Pública General GNU en <http://www.geog.uu.nl/gstat/>. Las modificaciones del código de Gstat realizadas por Clark Labs están disponibles en la sección de descargas del sitio web de Clark Labs: <http://www.clarklabs.org>.

<sup>128</sup> Los puntos en un par son identificados como el punto *desde* y el punto *hacia*. Ningún par se repite.






Figura 26-1

Par	Distancia de Separación	Dirección de Separación
AB	80 m	100
AC	50 m	0
BC	85 m	235

Tabla 26-1

La dirección se mide en grados, en sentido horario desde el norte de la grilla. Al igual que la distancia, la dirección por lo general es especificada como un rango en lugar de un solo acimut.

El diagrama de dispersión es usado como una técnica de visualización para explorar la variabilidad en los pares de datos de muestra. En el diagrama de dispersión, el eje X representa el atributo en un punto del par (el punto *desde*) y el eje Y representa ese mismo atributo en el otro punto del par (punto *hacia*). El diagrama de dispersión puede usarse para representar todos los pares, pero usualmente está restringido a la selección de pares basándose en determinado intervalo y/o dirección. La Figura 26-2 muestra la distribución espacial de 250 puntos muestrales de lluvia en un área de 1000 Km<sup>2</sup>. Estos puntos han sido colocados en pares, y los pares de datos que se hallan dentro del intervalo 1 (0-1 Km) y para todas las direcciones, están representados en el diagrama de dispersión ilustrado en la Figura 26-3.




Figura 26-2




Figura 26-3

El diagrama de dispersión generalmente es usado para tener una idea de qué aspectos de la distribución de pares de datos influyen el resumen de la variabilidad para un intervalo particular. Los diagramas de dispersión son interpretados determinando la dispersión de los puntos. Por ejemplo, si los pares estuvieran perfectamente correlacionados en forma lineal (es decir, sin variabilidad en esta separación y dirección), entonces todos los puntos se encontrarían sobre una línea.

Un patrón de puntos muy difuso en el diagrama de dispersión indica una variabilidad alta para los rangos de distancia y dirección dados. El diagrama de dispersión está disponible por medio de la interfase Spatial Dependence Modeler (Modelador de Dependencia Espacial).

El semivariograma es otra herramienta para la exploración y la descripción de la variabilidad espacial y también se encuentra disponible por medio de la interfase Modelador de Dependencia Espacial. Éste resume la información de variabilidad de los diagramas de dispersión y puede ser representado como un gráfico de superficie y como un

gráfico direccional. El gráfico de superficie muestra la variabilidad promedio en todas las direcciones en intervalos diferentes. La posición central en el gráfico, llamada el *origen*, representa la ausencia de intervalos. Los intervalos aumentan desde el centro hacia los bordes. La dirección es representada en el gráfico de superficie con el norte de la grilla directamente arriba desde el pixel central, 90 grados directamente hacia la derecha, y así sucesivamente.<sup>129</sup> La magnitud de la variabilidad es representada en color usando la paleta por defecto de IDRISI. Los valores bajos se muestran en colores más oscuros y los valores altos, en colores más brillantes. Cuando uno mueve el cursor sobre el gráfico de superficie, su ubicación, en términos de dirección y distancia desde el origen, aparece en la parte inferior del gráfico.

En la Figura 23-4 se ilustra un semivariograma en gráfico de superficie de la misma muestra de puntos de lluvia de la Figura 23-2. La distancia del intervalo está establecida en 1Km. Se puede observar claramente que en la dirección Oeste- Este, hay poca variabilidad entre los pares en todos los intervalos. Parece que la dirección de la variabilidad mínima (es decir, continuidad máxima) es de aproximadamente 95 (y 275) grados. Se presume que los puntos de datos que están separados uno del otro en esta dirección tienen atributos más similares que los puntos de datos separados por la misma distancia pero en dirección diferente.

La otra forma gráfica del semivariograma es el gráfico direccional, como el que se muestra en la Figura 26-5. Éste se utiliza para desarrollar las estructuras que describen los patrones de variabilidad (variability) en los datos. En el gráfico direccional, se marca un solo punto de resumen por cada intervalo. El eje X muestra la distancia (distance) de separación, detallada en unidades de referencia (Ej.: Km.), mientras que el eje Y muestra la variabilidad promedio para los pares de datos de muestra que se hallan dentro de cada intervalo. Se pueden considerar todos los pares sin importar la dirección (un esquema omnidireccional), o la representación puede estar limitada a los pares de un rango particular de direcciones.




Figura 26-4





Figura 26-5

Usualmente, uno comienza generando un semivariograma omnidireccional. Del gráfico omnidireccional, uno puede darse una idea sobre la variabilidad general de los datos. Luego el usuario puede crear varios gráficos, usando direcciones y distancias de intervalo diferentes, para conocer mejor la estructura del grupo de datos.

La estructura de los datos puede describirse según cuatro parámetros: la *meseta* (sill), el *rango* (range), el *nugget* (nugget) y la *anisotropía* (anisotropy). Los tres primeros están representados en la Figura 26-6. En la mayoría de los casos relacionados con datos ambientales, la variabilidad espacial entre los pares de muestra aumenta a medida que aumenta la distancia de separación. Eventualmente, la variabilidad alcanza una *meseta* donde un aumento en la distancia de separación entre los pares ya no aumenta la variabilidad entre estos, es decir, no hay dependencia espacial en esta distancia ni en otras mayores. La distancia de separación total desde la menor varianza hasta la meseta se conoce como *rango*. El rango señala la distancia más allá de la cual los datos de muestra no deben ser considerados en el proceso de interpolación cuando se seleccionan puntos que definen una vecindad local.

<sup>129</sup> Tenga en cuenta que algunos software geoestadísticos marcan cero grados a la derecha, en lugar de en la parte superior del gráfico de superficie.



**Figura 26-6**

El *nugget* se refiere a la varianza en una distancia de separación de cero, es decir, la ordenada al origen y de la curva que está colocada en los datos. En teoría, distancia entre pares suponemos que esta distancia es cero. Sin embargo, el ruido o la incertidumbre en términos espaciales, y esto resulta en un valor distinto de cero, o un efecto *nugget*. Una estructura *nugget* aumenta la variabilidad de forma uniforme en todo el gráfico porque no está relacionada con la distancia o la dirección de separación.

El cuarto parámetro que define la estructura es la anisotropía del grupo de datos. La transición de la continuidad espacial puede ser igual en todas las direcciones, es decir, la variación depende solamente de la distancia de separación. Esto se conoce como un *modelo isotrópico*. Un modelo ajustado a cualquier dirección es bueno en todas las direcciones. En la mayoría de los grupos de datos ambientales, en cambio, la variabilidad no es isotrópica. Los datos usados en la Figura 26-2, por ejemplo, exhiben una dirección mínima de variabilidad en la dirección Oeste-Este. En cualquier otra dirección, la variabilidad aumenta más rápido en la misma distancia de separación. Este tipo de datos requiere un *modelo anisotrópico*.

La anisotropía se describe por medio de ejes direccionales de continuidad mínima y máxima. Para determinar los parámetros que se van a emplear, el usuario considera semivariogramas direccionales para múltiples direcciones.

En los procesos de interpolación por kriging y simulación, las estructuras que describen el patrón de variabilidad espacial representado por semivariogramas direccionales son utilizadas para determinar la influencia de la dependencia espacial sobre las vecindades de puntos muestrales seleccionados para predecir puntos desconocidos. Las estructuras influyen cómo se deben ponderar sus atributos cuando se combinan para producir un valor interpolado. Los semivariogramas, en cambio, debido a que se basan en la falta de integridad inherente de los datos de muestra, necesitan curvas más suaves que definan la forma de la variabilidad espacial en todas las distancias de separación. Al usar información complementaria y semivariogramas, las funciones matemáticas son combinadas para delinear una curva suave de variabilidad espacial. En este paso, una estructura *nugget*, y las mesetas, rangos y anisotropías de estructuras adicionales son definidas para la curva suave. La interfase Model Fitting (Ajuste del Modelo) ofrece varias funciones matemáticas que pueden emplearse para diseñar una curva para la variabilidad espacial. Aquellas funciones que no forman una meseta en distancias de separación grandes, como las funciones lineal y potencial, se llaman no transitivas. Aquellas que sí alcanzan una meseta, como las funciones gaussiana y exponencial, se llaman funciones transitivas.

Juntos, la estructura *nugget*, y las mesetas, rangos y anisotropías de estructuras adicionales definen matemáticamente un modelo ensamblado de variabilidad espacial. Este se usa cuando se derivan en el ámbito local los pesos para los atributos de los datos de muestra dentro de la vecindad de un lugar que va a ser interpolado. Al usar la interfase Modelador de Dependencia Espacial, uno descubre un patrón de variabilidad espacial a través de la generación de varios variogramas hasta que se pueda determinar un semivariograma representativo. Por medio de la interfase Ajuste del Modelo, el usuario coloca una curva matemática descrita por mesetas, rangos, un *nugget*, anisotropía y funciones seleccionadas en la variabilidad espacial detectada. Esta curva se emplea para derivar los pesos aplicados a las muestras seleccionadas en el ámbito local durante la interpolación por kriging o simulación condicional.

Los semivariogramas son medidas estadísticas que suponen que los datos de entrada están normalmente distribuidos y que las desviaciones media y estándar de la vecindad local no muestran tendencias. Cada grupo de datos de muestra debe ser evaluado para detectar su conformidad con estas suposiciones. Las transformaciones de los datos, la edición del grupo de datos y la selección de diferentes estimadores estadísticos de la variabilidad espacial se emplean para manejar los grupos de datos que se alejan de las suposiciones.

La habilidad para identificar la variabilidad espacial verdadera en un grupo de datos depende en gran medida del conocimiento complementario sobre el fenómeno subyacente medido. Este proceso de detección también se puede mejorar con la inclusión de otros datos de atributo. El variograma cruzado, al igual que el semivariograma, marca la variabilidad en las distancias de grupos de datos enlazados y usa un grupo de datos para ayudar a explicar y mejorar la descripción de la variabilidad en otro grupo. Por ejemplo, cuando se interpola una superficie de lluvias a partir de datos puntuales de lluvia, la incorporación de una variable altamente correlacionada tal como la elevación, puede ayudar a perfeccionar la estimación de la lluvia. En los casos donde la correlación se conoce, los datos de elevación muestreados se pueden emplear para ayudar a predecir una superficie de lluvia, especialmente en aquellas áreas donde el muestreo de lluvia es escaso.

El semivariograma y otro método, el estimador robusto del semivariograma, son las medidas de variabilidad usadas para el ajuste final de un modelo de variabilidad que será utilizado con el grupo de datos. También son los únicos estimadores de variabilidad usados por IDRISI para el kriging y la simulación. No obstante, hay otros métodos para la detección de la continuidad espacial disponibles a través de la interfase Modelador de Dependencia Espacial. Estos incluyen el correlograma, el correlograma cruzado, el covariograma y el covariograma cruzado.


## Kriging y Simulación Condicional

La interfase Kriging y de Simulación utiliza el modelo desarrollado en las interfases Modelador de Dependencia Espacial y Ajuste del Modelo para interpolar una superficie. El modelo se emplea para derivar información sobre la continuidad espacial que define cómo se van a ponderar los datos de muestra cuando se combinan para producir los valores para los puntos desconocidos. Los pesos asociados con puntos muestrales se determinan por la dirección y la distancia con respecto a otros puntos conocidos, así como también por el número y carácter de los puntos de datos en una vecindad local definida por el usuario.

Con un kriging común, la varianza de los errores del ajuste del modelo es minimizada. Por ello se lo conoce como Mejor Estimador Lineal Imparcial (B.L.U.E).

Al ajustar un modelo suave de variabilidad espacial a los datos de muestra y al minimizar el error del ajuste de los datos de muestra, el kriging tiende a subestimar los valores bajos y sobreestimar los altos. El kriging minimiza el error producido por las diferencias en el ajuste de la continuidad espacial en cada vecindad local. Al hacer esto, el kriging produce una superficie suave.

La superficie mostrada en la Figura 26-7 fue producida con un kriging usando los puntos de precipitación de muestra ilustrados en la Figura 26-2.



**Figura 26-7**

La meta de kriging es reducir el grado de error de varianza en la estimación en la superficie. El error de varianza es una medida de la exactitud de la ajuste del modelo y de los parámetros de la vecindad para los datos de muestra, no la superficie real medida. Uno sólo puede interpretar esta información en términos del conocimiento acerca de lo bien que los datos de muestra representan la superficie real. Mientras más uniforme sea la ajuste del modelo espacial, más probabilidades hay de que sea bueno. El error de varianza es utilizado para identificar problemas en los datos de muestra, en los parámetros del modelo y en la definición de la vecindad local. Éste no es una medida de exactitud de la superficie.

En IDRISI, hay dos herramientas disponibles para evaluar la ajuste del modelo a los datos de muestra. Primero, la herramienta de validación cruzada elimina iterativamente un punto de datos de muestra e interpola un nuevo valor para la ubicación. Se produce una tabla para mostrar la diferencia entre los atributos pronosticados y los atributos conocidos en esas ubicaciones. Segundo, se produce una imagen de varianza que muestra la variación espacial de incertidumbre como resultado del modelo ajustado. Ésta provee información para asistir en la identificación de las áreas con problemas donde la relación entre el modelo ajustado y los puntos muestrales es pobre.

El Cokriging es una extensión del kriging que usa un segundo grupo de puntos de atributos diferentes para ayudar en el proceso de predicción. Los dos atributos deben estar altamente correlacionados entre sí para poder derivar algún beneficio. La descripción de la variabilidad espacial de la variable agregada se puede emplear en el proceso de interpolación, particularmente en áreas donde los puntos muestrales originales son escasos.

En la simulación condicional, un elemento de variabilidad independiente en términos espaciales es agregado al modelo previamente desarrollado. La variabilidad de cada punto interpolado se emplea para elegir al azar otra estimación. La superficie resultante mantiene la variabilidad espacial como la ha definido el modelo del semivariograma, pero además representa la variabilidad pixel por pixel. La superficie resultante no es suave. Usualmente, muchas de estas superficies (tal vez cientos de ellas) son producidas, cada una representando un modelo de la realidad. Las superficies se diferencian entre sí debido a la selección aleatoria de las estimaciones. La simulación condicional es más adecuada para el desarrollo de representaciones múltiples de una superficie que pueden servir como entradas para un análisis Monte Carlo de un modelo de proceso.

## Resumen

La geoestadística brinda una gran colección de herramientas para explorar y comprender la naturaleza de un grupo de datos. En lugar de simplemente buscar producir una superficie interpolada visualmente satisfactoria, uno se involucra en el análisis geoestadístico con el propósito principal de entender por qué varios métodos producen resultados particulares y diferentes. La interpretación de la información presentada a través de varias técnicas depende del conocimiento de otras características de los datos y de la superficie real. Mientras que las mismas medidas de variabilidad espacial son estadísticas descriptivas relativamente simples, se requiere práctica y experiencia para entender cómo éstas pueden usarse con los grupos de datos que se alejan de las suposiciones ideales.

## Referencias / Lectura Complementaria

El análisis geoestadístico es un campo bien desarrollado con bastante literatura relacionada disponible. La breve lista expuesta a continuación debería brindar una buena introducción a la exploración geoestadística para aquellos que ya tienen un buen manejo de las estadísticas.

Burrough, P., y McDonnell, R., 1998. *Principles of Geographical Information Systems*, 98-161, Oxford University Press, Oxford.

Cressie, N., 1991. *Statistics for Spatial Data*, John Wiley e Hijos, Inc., Nueva York.

Cressie, N., y Hawkins, D., 1980. *Robust Estimation of the Variogram*, *Journal International Association of Mathematical eology*, 12:115-125. Deutsch, C., y Journel, A., 1998. *GSLIB Geostatistical Software Library and User's Guide, 2nd Edition*, Oxford University Press, Oxford.

Goovaerts, P., 1997. *Geostatistics for Natural Resources Evaluation*, Oxford University Press, Oxford.

Issaks, E., y Srivastava, R., 1989. *Applied Geostatistics*, Oxford University Press, Oxford.

Journel, A., y Huijbregts, C., 1978. *Mining Geostatistics*, Academic Press, Nueva York.

Myers, J., 1997. *Geostatistical Error Management: Quantifying Uncertainty for Environmental Sampling and Mapping*, Van Nostrand Reinhold, Nueva York.

Pebesma, E., 1991-1998. Gstat, GNU Software Foundation.

Pebesma, E., y Wesseling, C., 1998. Gstat: A Program for Geostatistical Modelling, Prediction and Simulation, *Computers and Geosciences*, 24(1): 17-31.

Soares, A., Gómez-Hernandez, J., y Froidevaux, R., eds., 1997. *geoENVI – Geostatistics for Environmental Applications*, Kluwer Academic Publishers, Dordrecht, Países Bajos.

Solow, A., y Ratick, S., 1994. Conditional Simulation and the Value of Information, In: *Geostatistics for the Next Century*, R. Simitrakopoulos (ed.), Kluwer Academic Publishers, Dordrecht, Países Bajos.

# APÉNDICE 1: Parámetros de los Elipsoides

Nombre del Elipsoide	Semiejes Principales	Semiejes Secundarios
Airy	6377563,396	6356256,909
Airy Modificado	6377340,189	6356034,448
Nacional Australiano	6378160,000	6356774,719
Sistema Terrestre Promedio 1997	6378135	6356750,305
Bessel 1841 (Etiopía, Indonesia, Japón, Corea)	6377397,155	6356078,963
Bessel 1841 (Namibia)	6377483,865	6356165,383
Bessel Modificado	6377492,018	6356173,509
Clarke 1858	20926348	20855233
Clarke 1866	6378206,400	6356583,800
Clarke 1866 Michigan	20926631,531	20855688,674
Clarke 1880	6378249,145	6356514,870
Clarke 1880 Benoit	6378300,789	6356566,435
Clarke 1880 IGN	6378249,2	6356515
Clarke 1880 (SGA 1922)	6378249,2	6356514,997
Everest - India 1830	6377276,345	6356075,413
Everest - India 1956	6377301,24	6356100,23
Everest - Pakistán	6377309,61	6356108,57
Everest - Sabah y Sarawak	6377298,56	6356097,55
Everest - Malasia Oeste 1969	6377295,66	6356094,67
Everest - Malasia Oeste y Singapur 1948	6377304,063	6356103,039
Everest (1830 definición)	20922931,8	20853374,58
Everest 1830 (1962 definición)	6377301,243	6356100,23
Everest 1830 (1967 definición)	6377298,556	6356097,55
Everest 1830 (1975 definición)	6377299,151	6356098,145
Fischer 1960	6378166,000	6356784,280
Fischer Modificado 1960	6378155,000	6356773,320
Fischer 1968	6378150,000	6356768,340
GEM 10C	6378137	6356752,314
GRS 1967	6378160	6356774,516

Nombre del Elipsoide	Semiejes Principales	Semiejes Secundarios
GRS 1980	6378137,000	6356752,314
Helmert 1906	6378200,000	6356818,170
Hough	6378270,000	6356794,343
Indonés 1974	6378160,00	6356774,50
Internacional 1924	6378388,000	6356911,946
Krassovsky 1940	6378245,000	6356863,019
NWL 9D	6378145	6356759,769
OSU86F	6378136,2	6356751,517
OSU91A	6378136,3	6356751,617
Plessis 1817	6376523	6355862,933
SGS 85	6378136,000	6356751,300
Sudamericano 1969	6378160,000	6356774,719
Esfera	6371000	6371000
Struve 1860	6378298,3	6356657,143
War Office	6378300,583	6356752,27
WGS 60	6378165,000	6356783,290
WGS 66	6378145,000	6356759,770
WGS 72	6378135,000	6356750,520
WGS 84	6378137,000	6356752,314



## APÉNDICE 2: Parámetros del Datum

La siguiente tabla contiene las constantes requeridas para el procedimiento de la Transformación del Datum Molodensky. Los valores  $\Delta X$ ,  $\Delta Y$  y  $\Delta Z$  son los tres valores (en ese orden) que deben especificarse en el campo "Delta WGS84" del Archivo de Parámetros del Sistema de Referencia. Estos valores representan la diferencia tridimensional en la posición del elipsoide del datum del WGS84. Los valores aquí detallados fueron tomados de la Base de Datos del Grupo Europeo de Relevamiento Petrolífero (European Petroleum Survey Group Database).

Datum	Ubicación	Elipsoide	DX	DY	DZ
ABIDJAN 1987	Cote D'Ivoire (Costa de Ivory)	Clarke 1880	-124,76	53	466,79
ABIDJAN	MEDIA PARA Etiopía, Sudán	Clarke 1880	-166	-15	204
	Burkina Faso		-118	-14	218
	Camerún		-134	-2	210
	Etiopía		-165	-11	206
	Malí		-123	-20	220
	Senegal		-128	-18	224
	Sudán		-161	-14	205
AFGOOYE	Somalia	Krassovsky 1940	-43	-163	45
AIN EL ABD 1970	Isla Bahrain	Internacional 1924	-150	-250	-1
	Arabia Saudita		-143	-236	7
SAMOA AMERICANA 1962	Islas Samoa Americanas	Clarke 1866	-115	118	426
AMERSFOORT	Países Bajos	Bessel 1841	593,16	26,15	478,54
ANNA 1 ASTRO 1965	Islas Cocos	Nacional Australiano	-491	-22	435
ISLA ANTIGUA ASTRO 1943	Antigua (Islas Leeward)	Clarke 1880	-270	13	62

Datum	Ubicación	Elipsoide	DX	DY	DZ
ARC 1950	MEDIA PARA Botswana, Lesotho, Malawi, Swazilandia, Zaire, Zambia, Zimbabwe	Clarke 1880	-143	-90	-294
	Botswana		-138	-105	-289
	Burundi		-153	-5	-292
	Lesotho		-125	-108	-295
	Malawi		-161	-73	-317
	Swazilandia		-134	-105	-295
	Zaire		-169	-19	-278
	Zambia		-147	-74	-283
	Zimbabwe		-142	-96	-293
ARC 1960	MEDIA PARA Kenya, Tanzania	Clarke 1880	-160	-6	-302
ISLA ASCENSIÓN 1958	Isla Ascensión	Internacional 1924	-205	107	53
ASTRO BEACON E 1945	Iwo Jima	Internacional 1924	145	75	-272
ASTRO DOS 71/4	Isla Santa Helena	Internacional 1924	-320	550	-494
ISLA ASTRO TERN (FRIG) 1961	Isla Tern	Internacional 1924	114	-116	-333
ESTACIÓN ASTRONÓMICA 1952	Isla Marcus	Internacional 1924	124	-234	-25
GEODESIA AUSTRALIANA 1966	Australia & Tasmania	Nacional Australiano	-133	-48	148
GEODESIA AUSTRALIANA 1984	Australia & Tasmania	Nacional Australiano	-134	-48	149
FARO AYABELLE	Djibouti	Clarke 1880	-79	-129	145
BATAVIA	Indonesia (Sumatra)	Bessel 1841	-377	681	-50
BELLEVUE (IGN)	Islas Efate & Erromango	Internacional 1924	-127	-769	472
BERMUDA 1957	Bermuda	Clarke 1866	-73	213	296
BISSAU	Guinea - Bissau	Internacional 1924	-173	253	27
OBSERVATORIO DE BOGOTA	Colombia	Internacional 1924	307	304	-318
BUKIT RIMPAH	Indonesia (Islas Bangka & Belitung)	Bessel 1841	-384	664	-48
ÁREA DE CAMPAMENTO ASTRO	Antártida (Área del Campamento McMurdo)	Internacional 1924	-104	-129	239
CAMPO INCHAUSPE	Argentina	Internacional 1924	-148	136	90
CANTON ASTRO 1966	Islas Phoenix	Internacional 1924	298	-304	-375
CABO	Sudáfrica	Clarke 1880	-136	-108	-292
CABO CAÑAVERAL	Bahamas, Florida	Clarke 1866	-2	151	181
CARTAGO	Túnez	Clarke 1880	-263	6	431
ISLA CHATHAM ASTRO 1971	Nueva Zelanda (Isla Chatham)	Internacional 1924	175	-38	113
CHTRF95	Liechtenstein, Suiza	GRS1980	()	()	()

Datum	Ubicación	Elipsoide	DX	DY	DZ
CHUA ASTRO	Paraguay	Internacional 1924	-134	229	-29
CORREGO ALEGRE	Brasil	Internacional 1924	-206	172	-6
DABOLA	Guinea130	Clarke 1880	-83	37	124
ISLA DECEPTION	Isla Deception, Antártida	Clarke 1880	260	12	-147
DJAKARTA (BATAVIA)	Indonesia (Sumatra)	Bessel 1841	-377	681	-50
DOMINICA 1945	Dominica	Clarke 1880	725	685	536
DOS 1968	Islas New Georgia (Isla Gizo)	Internacional 1924	230	-199	-752
ISLA EASTER 1967	Isla Easter	Internacional 1924	211	147	111
EGIPTO 1907	Egipto	Helmert 1906	-130	110	-13
EST92	Estonia	GRS80	0,055	-0,541	-0,185
ETRF89	Europa	GRS80	0	0	0
EUROPEO 1950	MEDIA PARA Austria, Bélgica, Dinamarca, Finlandia, Francia, Alemania Oeste, Gibraltar, Grecia, Italia, Luxemburgo, Países Bajos, Noruega, Portugal, España, Suecia, Suiza	Internacional 1924	-87	-98	-121
	MEDIA PARA Austria, Dinamarca, Francia, Alemania Oeste, Países Bajos, Suiza		-87	-96	-120
	MEDIA PARA Irak, Israel, Jordania, Líbano, Kuwait, Arabia Saudita, Siria		-103	-106	-141
	Chipre		-104	-101	-140
	Egipto		-130	-117	-151
	Inglaterra, Islas Channel, Irlanda, Escocia, Islas Shetland		-86	-96	-120
	Finlandia, Noruega		-87	-95	-120
	Francia		-84	-97	-117
	Grecia		-84	-95	-130
	Irán		-117	-132	-164
	Italia (Cerdeña)		-97	-103	-120
	Italia (Sicilia)		-97	-88	-135
	Malta		-107	-88	-149
	Portugal, España		-84	-107	-120
	Túnez		-112	-77	-145
	Reino Unido UKCS costa este de 6 Grad. oeste		-89,5	-93,8	-123,1

EUROPEO 1979	MEDIA PARA Austria, Finlandia, Países Bajos, Noruega, España, Suecia, Suiza	Internacional 1924	-86	-98	-119
Fahud					
FD58	Iran (distrito de Kangan)	Clarke 1880	-241.54	-163.64	396.06
FORT THOMAS 1955	Nevis, St. Kitts (Leeward Islands)	Clarke 1880	-7	215	225
GAN 1970	República de Maldivas	Internacional 1924	-133	-321	50
GEODETIC DATUM 1949	Nueva Zelandia	Internacional 1924	84	-22	209
GGRS87	Grecia	GRS 1980	-199.87	74.79	246.62
GRACIOSA BASE SW 1948	Azores (Faial, Graciosa, Pico, Sao Jorge, Terceira)	Internacional 1924	-104	167	-38
GRENADA 1953	Granada	Clarke 1880	72	213.7	93
GUAM 1963	Guam	Clarke 1866	-100	-248	259
GUNUNG SEGARA	Indonesia (Kalimantan)	Bessel 1841	-403	684	41
GUX 1 ASTRO	Isla de Guadalcanal	Internacional 1924	252	-209	-751
HERAT NORTH	Afganistán	Internacional 1924	-333	-222	114
HJORSEY 1955	Islandia	Internacional 1924	-73	46	-86
HONG KONG 1963	Hong Kong	Internacional 1924	-156	-271	-189
HU-TZU-SHAN	Taiwan	Internacional 1924	-637	-549	-203
INDIAN	Bangladesh	Everest 1830	282	726	254
INDIAN	India, Nepal	Everest 1956	295	736	257
INDIAN	Pakistan	Everest	283	682	231
INDIAN 1954	Tailandia	Everest 1830	217	823	299
INDIAN 1960	Vietnam (cerca de 16°N) Con Son Island (Vietnam)	Everest 1830	198 182	881 915	317 344
INDIAN 1975	Tailandia	Everest 1830	209	818	290
INDONESIAN 1974	Indonesia	Indonesio 1974	-24	-15	5
IRELAND 1965	Irlanda	Airy modificado	506	-122	611
ISTS 061 ASTRO 1968	Islas Georgia del Sur	Internacional 1924	-794	119	-298
ISTS 073 ASTRO 1969	Diego Garcia	Internacional 1924	208	-435	-229
JOHNSTON ISLAND 1961	Isla Johnston	Internacional 1924	189	-79	-202
KANDAWALA	Sri Lanka	Everest 1830	-97	787	86
KERGUELEN ISLAND 1949	Isla Kerguelen	Internacional 1924	145	-187	103
KERTAU 1948	Malaysia Oeste & Singapore	Everest 1948	-11	851	5

Datum	Ubicación	Elipsoide	DX	DY	DZ
KUSAIE ASTRO 1951	Islas Caroline, Estados Federales de Micronesia	Internacional 1924	647	1777	-1124
L. C. 5 ASTRO 1961	Isla Cayman Brac	Clarke 1866	42	124	147
LEIGON	Ghana	Clarke 1880	-130	29	364
LIBERIA 1964	Liberia	Clarke 1880	-90	40	88
LUZON	Filipinas (Excluyendo Mindanao)	Clarke 1866	-133	-77	-51
	Filipinas (Mindanao)		-133	-79	-72
MAHE 1971	Isla Mahe	Clarke 1880	41	-220	-134
MASSAWA	Etiopía (Eritrea)	Bessel 1841	639	405	60
MERCHICH	Marruecos	Clarke 1880	31	146	47
MIDWAY ASTRO 1961	Isla Midway	Internacional 1924	912	-58	1227
MINNA	Camerún	Clarke 1880	-81	-84	115
	Nigeria		-92	-93	122
MONTERRAT ISLAND ASTRO 1958	Montserrat (Islas Leeward)	Clarke 1880	174	359	365
M'PORALOKO	Gabón	Clarke 1880	-74	-130	42
NAHRWAN	Omán (Isla Masirah)	Clarke 1880	-247	-148	369
	Arabia Saudita		-243	-192	477
	Emiratos Árabes Unidos		-249	-156	381
NAPARIMA BWI	Trinidad & Tobago	Internacional 1924	-10	375	165

DATUM	LOCATION	ELLIPSOID	DX	DY	DZ
AMERICA DEL NORTE 1927	MEDIA PARA Antigua y Barbuda, Barbados, Barbuda, Islas Caicos, Cuba, República Dominicana, Gran Caimán, Jamaica, Islas Turcas	Clarke 1866	-3	142	183
	MEDIA PARA Belize, Costa Rica, El Salvador, Guatemala, Honduras, Nicaragua		0	125	194
	MEDIA PARA Canada		-10	158	187
	MEDIA PARA EEUU Continental (CONUS)		-8	160	176
	MEDIA PARA CONUS (Este del Río Mississippi) Including Louisiana, Missouri, Minnesota		-9	161	179
	MEDIA PARA CONUS (Oeste del Río Mississippi)				
	Alaska (Excluyendo las Islas Aleutianas)		-8	159	175
	Islas Aleutianas (Al este de 180°W)		-5	135	172
	Islas Aleutianas (Al oeste de 180°W)		-2	152	149
	Bahamas (Excepto Isla San Salvador)		2	204	105
	Bahamas (Isla San Salvador )		-4	154	178
	Canada (Alberta, British Columbia)		1	140	165
	Canada (Manitoba, Ontario)		-7	162	188
	Canada (New Brunswick, Newfoundland, Nova Scotia, Quebec)		-9	157	184
	Canada (Northwest Territories, Saskatchewan)		-22	160	190
	Canada (Yukon)				
	Zona Canal Cuba		4	159	188
	Groenlandia (Península Hayes)		-7	139	181
	México		0	125	201
			-9	152	178
			11	114	195
			-12	130	190
AMERICA DEL NORTE 1983	Alaska (Excluyendo las Islas Aleutianas), Canada, America Central, CONUS, México	GRS 80	0	0	0
	Islas Aleutianas		-2	0	4
	Hawaii		1	1	-1
SAHARA NORTE 1959	Algeria	Clarke 1880	-186	-93	310
OBSERVATORIO METEOREO 1939	Azores (Corvo & Islas Flores)	International 1924	-425	-169	81
ANTIGUO EGIPTO 1907	Egipto	Helmert 1906	-130	110	-13

Datum	Ubicación	Elipsoide	DX	DY	DZ
VIEJO HAWAIANO	MEDIA PARA Hawai, Kauai, Maui, Oahu	Clarke 1866	61	-285	-181
	Hawai		89	-279	-183
	Kauai		45	-290	-172
	Maui		65	-290	-190
	Oahu		58	-283	-182
OMÁN	Omán	Clarke 1880	-346	-1	224
ORD. SURVEY GRAN BRETAGNA 1936	MEDIA PARA Inglaterra, Isla de Man, Escocia, Islas Shetland, Gales	Airy	375	-111	431
	Inglaterra		371	-112	434
	Inglaterra, Isla de Man, Gales		371	-111	434
	Escocia, Islas Shetland		384	-111	425
	Gales		370	-108	434
PICO DE LAS NIEVES	Islas Canarias	Internacional 1924	-307	-92	127
PITCAIRN ASTRO 1967	Isla Pitcairn	Internacional 1924	185	165	42
POINT 58	MEDIA PARA Burkina Faso & Nigeria	Clarke 1880	-106	-129	165
POINTE NOIRE 1948	Congo	Clarke 1880	-148	51	-291
PORTO SANTO 1936	Porto Santo, Islas Madeira	Internacional 1924	-499	-249	314
PROVISIONAL SUDAMERICANO 1956	MEDIA PARA Bolivia, Chile, Colombia, Ecuador, Guyana, Perú, Venezuela	Internacional 1924	-288	175	-376
	Bolivia		-270	188	-388
	Chile (Norte, Cerca de 19°S)		-270	183	-390
	Chile (Sur, Cerca de 43°S)		-305	243	-442
	Colombia		-282	169	-371
	Ecuador		-278	171	-367
	Guyana		-298	159	-369
	Perú		-279	175	-379
	Venezuela		-295	173	-371
PROVISIONAL CHILENO SUR 1963	Chile (Sur, Cerca de 53°S) (Hito XVIII)	Internacional 1924	16	196	93
PUERTO RICO	Puerto Rico, Islas Vírgenes	Clarke 1866	11	72	-101
PULKOVO 1942	Rusia	Krassovsky 1940	28	-130	-95
QATAR NACIONAL	Qatar	Internacional 1924	-128	-283	22
QORNOQ	Groenlandia (Sur)	Internacional 1924	164	138	-189

Datum	Ubicación	Elipsoide	DX	DY	DZ
REUNIÓN	Islas Mascarene	Internacional 1924	94	-948	-1262
ROMA 1940	Italia (Cerdeña)	Internacional 1924	-225	-65	9
S-42 (PULKOVO 1942)	Hungría	Krassovsky 1940	28	-121	-77
SANTO (DOS) 1965	Isla Espíritu Santo	Internacional 1924	170	42	84
SAO BRAZ	Azores (Islas Sao Miguel, Santa Maria)	Internacional 1924	-203	141	53
SAPPER HILL 1943	Isla Soledad-Malvinas (East Falkland Island)	Internacional 1924	-355	21	72
SCHWARZECK	Namibia	Bessel 1841 (Namibia)	616	97	-251
SELVAGEM GRANDE 1938	Isla Salvage	Internacional 1924	-289	-124	60
SGS 85	Sistema Geodésico Soviético 1985	SGS 85	3	9	-9
S-JTSK	Checoslovaquia (antes del 1 de enero, 1993)	Bessel 1841	589	76	480
SUDAMERICANO 1969	MEDIA PARA Argentina, Bolivia, Brasil, Chile, Colombia, Ecuador, Guyana, Paraguay, Perú, Trinidad & Tobago, Venezuela	Sudamericano 1969	-57	1	-41
	Argentina		-62	-1	-37
	Bolivia		-61	2	-48
	Brasil		-60	-2	-41
	Chile		-75	-1	-44
	Colombia		-44	6	-36
	Ecuador (Excluyendo las Islas Galápagos)		-48	3	-44
	Ecuador (Baltra, Galápagos)		-47	26	-42
	Guyana		-53	3	-47
	Paraguay		-61	2	-33
	Perú		-58	0	-44
	Trinidad & Tobago		-45	12	-33
	Venezuela		-45	8	-33
SUR DE ASIA	Singapur	Fischer Modificado 1960	7	-10	-26
OBSERVATORIO TANANARIVE 1925	Madagascar	Internacional 1924	-189	-242	-91
TIMBALAI 1948	Brunei, Este de Malasia (Sabah, Sarawak)	Everest (Sabah & Sarawak)	-679	669	-48



Datum	Ubicación	Elipsoide	DX	DY	DZ
TOKYO	MEDIA PARA Japón, Okinawa, Corea del Sur	Bessel 1841	-148	507	685
	Japón		-148	507	685
	Okinawa		-158	507	676
	Corea del Sur		-146	507	687
TRISTAN ASTRO 1968	Tristan da Cunha	Internacional 1924	-632	438	-609
VOIROL 1960	Algeria	Clarke 1880	-123	-206	219
VITI LEVU 1916	Fiji (Isla Viti Levu)	Clarke 1880	51	391	-36
WAKE-ENIWETOK 1960	Islas Marshall	Hough	102	52	-38
ISLA WAKE ASTRO 1952	Wake Atoll	Internacional 1924	276	-57	149
WGS 1972	Definición Global	WGS 72	0	0	0
YACARE	Uruguay	Internacional 1924	-155	171	37
ZANDERIJ	Surinam	Internacional 1924	-265	120	-358

# APÉNDICE 3: Archivos de Parámetros Suministrados para el Sistema de Referencia

## Geodesia (Latitud / Longitud)

Un solo archivo REF llamado LATLONG es suministrado para las coordenadas geodésicas. Este archivo está basado en el datum WGS84. Para otros *datums*, utilice la función COPY del Explorador de Archivos del IDRISI para copiar este archivo con otro nombre y luego use el Metadata o Edit junto con los datos de los **Apéndices 1 y 2** para ingresar la información del nuevo *datum*.

## Mercator Universal Transversal (UTM)

160 archivos REF son suministrados para el sistema UTM – 60 para el hemisferio norte usando el datum WGS84, 60 para el hemisferio sur usando el datum WGS84, 20 para América del Norte basándose en el datum NAD27 y 20 para América del Norte basándose en el datum NAD83. El grupo WGS84 del norte posee nombres que van desde UTM-01N a UTM-60N, mientras que el grupo WGS84 del sur posee nombres que van desde UTM-01S a UTM-60S. El grupo NAD27 (que cubre las zonas 1 a 20) posee nombres que van desde US27TM01 a US27TM20, mientras que aquellos para NAD83 van desde US83TM01 a US83TM20. Observe que los grupos de América del Norte usan un valor de media norteamericano para las constantes Molodensky.

Para otros datum, se puede usar el módulo UTMREF para crear el archivo de parámetros del sistema de referencia. Además, varias instancias muy específicas del sistema UTM se encuentran disponibles en el grupo Misceláneo, incluido más adelante en el apéndice.

## Sistema Plano de Coordenadas de los Estados De Estados Unidos 1927

Hay archivos REF suministrados para todos los Sistemas Plano de Coordenadas de los Estados de Estados Unidos en las proyecciones Mercator Transversal y Cónica Conformal de Lambert para NAD27 y NAD83. La siguiente tabla especifica estos archivos para el datum NAD27. La columna *Proyección* indica la proyección en la cual se basa el sistema (L=Lambert Conformal Conic / TM=Transversa Mercator).

Estado	Nombre del Archivo	Título	Proyección
Alabama	SPC27AL1	Sistema Plano de Coordenadas del Estado de Alabama Zona Este	TM
	SPC27AL2	Sistema Plano de Coordenadas del Estado de Alabama Zona Oeste	TM
Alaska	SPC27AK0	Sistema Plano de Coordenadas del Estado de Alaska Zona 10	TM
	SPC27AK2	Sistema Plano de Coordenadas del Estado de Alaska Zona 2	TM
	SPC27AK3	Sistema Plano de Coordenadas del Estado de Alaska Zona 3	TM
	SPC27AK4	Sistema Plano de Coordenadas del Estado de Alaska Zona 4	TM
	SPC27AK5	Sistema Plano de Coordenadas del Estado de Alaska Zona 5	TM
	SPC27AK6	Sistema Plano de Coordenadas del Estado de Alaska Zona 6	TM

Estado	Nombre del Archivo	Título	Proyección
	SPC27AK7	Sistema Plano de Coordenadas del Estado de Alaska Zona 7	TM
	SPC27AK8	Sistema Plano de Coordenadas del Estado de Alaska Zona 8	TM
	SPC27AK9	Sistema Plano de Coordenadas del Estado de Alaska Zona 9	TM
Arizona	SPC27AZ1	Sistema Plano de Coordenadas del Estado de Arizona Zona Este	TM
	SPC27AZ2	Sistema Plano de Coordenadas del Estado de Arizona Zona Central	TM
	SPC27AZ3	Sistema Plano de Coordenadas del Estado de Arizona Zona Oeste	TM
Arkansas	SPC27AR1	Sistema Plano de Coordenadas del Estado de Arkansas Zona Norte	L
	SPC27AR2	Sistema Plano de Coordenadas del Estado de Arkansas Zona Sur	L
California	SPC27CA1	Sistema Plano de Coordenadas del Estado de California Zona I	L
	SPC27CA2	Sistema Plano de Coordenadas del Estado de California Zona II	L
	SPC27CA3	Sistema Plano de Coordenadas del Estado de California Zona III	L
	SPC27CA4	Sistema Plano de Coordenadas del Estado de California Zona IV	L
	SPC27CA5	Sistema Plano de Coordenadas del Estado de California Zona V	L
	SPC27CA6	Sistema Plano de Coordenadas del Estado de California Zona VI	L
	SPC27CA7	Sistema Plano de Coordenadas del Estado de California Zona VII	L
Carolina del Norte	SPC27NC1	Sistema Plano de Coordenadas del Estado de Carolina del Norte Zona 1	L
Carolina del Sur	SPC27SC1	Sistema Plano de Coordenadas del Estado de Carolina del Sur Zona Norte	L
	SPC27SC2	Sistema Plano de Coordenadas del Estado de Carolina del Sur Zona Sur	L
Colorado	SPC27CO1	Sistema Plano de Coordenadas del Estado de Colorado Zona Norte	L
	SPC27CO2	Sistema Plano de Coordenadas del Estado de Colorado Zona Central	L
	SPC27CO3	Sistema Plano de Coordenadas del Estado de Colorado Zona Sur	L
Connecticut	SPC27CT1	Sistema Plano de Coordenadas del Estado de Connecticut Zona 1	L
Dakota del Norte	SPC27ND1	Sistema Plano de Coordenadas del Estado de Dakota del Norte Zona Norte	L
	SPC27ND2	Sistema Plano de Coordenadas del Estado de Dakota del Norte Zona Sur	L
Dakota del Sur	SPC27SD1	Sistema Plano de Coordenadas del Estado de Dakota del Sur Zona Norte	L
	SPC27SD2	Sistema Plano de Coordenadas del Estado de Dakota del Sur Zona Sur	L
Delaware	SPC27DE1	Sistema Plano de Coordenadas del Estado de Delaware Zona 1	TM
Florida	SPC27FL1	Sistema Plano de Coordenadas del Estado de Florida Zona Este	TM
	SPC27FL2	Sistema Plano de Coordenadas del Estado de Florida Zona Oeste	TM
	SPC27FL3	Sistema Plano de Coordenadas del Estado de Florida Zona Norte	TM
Georgia	SPC27GA1	Sistema Plano de Coordenadas del Estado de Georgia Zona Este	TM
	SPC27GA2	Sistema Plano de Coordenadas del Estado de Georgia Zona Oeste	TM
Hawai	SPC27HI1	Sistema Plano de Coordenadas del Estado de Hawai Zona 1	TM
	SPC27HI2	Sistema Plano de Coordenadas del Estado de Hawai Zona 2	TM

Estado	Nombre del Archivo	Título	Proyección
	SPC27HI3	Sistema Plano de Coordenadas del Estado de Hawai Zona 3	TM
	SPC27HI4	Sistema Plano de Coordenadas del Estado de Hawai Zona 4	TM
	SPC27HI5	Sistema Plano de Coordenadas del Estado de Hawai Zona 5	TM
Idaho	SPC27ID1	Sistema Plano de Coordenadas del Estado de Idaho Zona Este	TM
	SPC27ID2	Sistema Plano de Coordenadas del Estado de Idaho Zona Central	TM
	SPC27ID3	Sistema Plano de Coordenadas del Estado de Idaho Zona Oeste	TM
Illinois	SPC27IL1	Sistema Plano de Coordenadas del Estado de Illinois Zona Este	TM
	SPC27IL2	Sistema Plano de Coordenadas del Estado de Illinois Zona Oeste	TM
Indiana	SPC27IN1	Sistema Plano de Coordenadas del Estado de Indiana Zona Este	TM
	SPC27IN2	Sistema Plano de Coordenadas del Estado de Indiana Zona Oeste	TM
Iowa	SPC27IA1	Sistema Plano de Coordenadas del Estado de Iowa Zona Norte	L
	SPC27IA2	Sistema Plano de Coordenadas del Estado de Iowa Zona Sur	L
Kansas	SPC27KS1	Sistema Plano de Coordenadas del Estado de Kansas Zona Norte	L
	SPC27KS2	Sistema Plano de Coordenadas del Estado de Kansas Zona Sur	L
Kentucky	SPC27KY1	Sistema Plano de Coordenadas del Estado de Kentucky Zona Norte	L
	SPC27KY2	Sistema Plano de Coordenadas del Estado de Kentucky Zona Sur	L
Louisiana	SPC27LA1	Sistema Plano de Coordenadas del Estado de Louisiana Zona Norte	L
	SPC27LA2	Sistema Plano de Coordenadas del Estado de Louisiana Zona Sur	L
	SPC27LA3	Sistema Plano de Coordenadas del Estado de Louisiana Zona Costera	L
Maine	SPC27ME1	Sistema Plano de Coordenadas del Estado de Maine Zona Este	TM
	SPC27ME2	Sistema Plano de Coordenadas del Estado de Maine Zona Oeste	TM
Maryland	SPC27MD1	Sistema Plano de Coordenadas del Estado de Maryland Zona 1	L
Massachusetts	SPC27MA1	Sistema Plano de Coordenadas del Estado de Massachusetts Zona Continental	L
	SPC27MA2	Sistema Plano de Coordenadas del Estado de Massachusetts Zona Isla	L
Michigan	SPC27MI1	Actual Sistema Plano de Coordenadas del Estado de Michigan Zona Norte	L
	SPC27MI2	Actual Sistema Plano de Coordenadas del Estado de Michigan Zona Central	L
	SPC27MI3	Actual Sistema Plano de Coordenadas del Estado de Michigan Zona Sur	L
	SPC27MI4	Antiguo Sistema Plano de Coordenadas del Estado de Michigan Zona Este	TM
	SPC27MI5	Antiguo Sistema Plano de Coordenadas del Estado de Michigan Zona Central	TM
	SPC27MI6	Antiguo Sistema Plano de Coordenadas del Estado de Michigan Zona Oeste	TM
Minnesota	SPC27MN1	Sistema Plano de Coordenadas del Estado de Minnesota Zona Norte	L
	SPC27MN2	Sistema Plano de Coordenadas del Estado de Minnesota Zona Central	L
	SPC27MN3	Sistema Plano de Coordenadas del Estado de Minnesota Zona Sur	L
Mississippi	SPC27MS1	Sistema Plano de Coordenadas del Estado de Mississippi Zona Este	TM

Estado	Nombre del Archivo	Título	Proyección
	SPC27MS2	Sistema Plano de Coordenadas del Estado de Mississippi Zona Oeste	TM
Missouri	SPC27MO1	Sistema Plano de Coordenadas del Estado de Missouri Zona Este	TM
	SPC27MO2	Sistema Plano de Coordenadas del Estado de Missouri Zona Central	TM
	SPC27MO3	Sistema Plano de Coordenadas del Estado de Missouri Zona Oeste	TM
Montana	SPC27MT1	Sistema Plano de Coordenadas del Estado de Montana Zona Norte	L
	SPC27MT2	Sistema Plano de Coordenadas del Estado de Montana Zona Central	L
	SPC27MT3	Sistema Plano de Coordenadas del Estado de Montana Zona Sur	L
Nebraska	SPC27NE1	Sistema Plano de Coordenadas del Estado de Nebraska Zona Norte	L
	SPC27NE2	Sistema Plano de Coordenadas del Estado de Nebraska Zona Sur	L
Nevada	SPC27NV1	Sistema Plano de Coordenadas del Estado de Nevada Zona Este	TM
	SPC27NV2	Sistema Plano de Coordenadas del Estado de Nevada Zona Central	TM
	SPC27NV3	Sistema Plano de Coordenadas del Estado de Nevada Zona Oeste	TM
Nueva Hampshire	SPC27NH1	Sistema Plano de Coordenadas del Estado de Nueva Hampshire Zona 1	TM
Nueva Jersey	SPC27NJ1	Sistema Plano de Coordenadas del Estado de Nueva Jersey Zona 1	TM
Nuevo México	SPC27NM1	Sistema Plano de Coordenadas del Estado de Nuevo México Zona Este	TM
	SPC27NM2	Sistema Plano de Coordenadas del Estado de Nuevo México Zona Central	TM
	SPC27NM3	Sistema Plano de Coordenadas del Estado de Nuevo México Zona Oeste	TM
Nueva York	SPC27NY1	Sistema Plano de Coordenadas del Estado de Nueva York Zona Este	TM
	SPC27NY2	Sistema Plano de Coordenadas del Estado de Nueva York Zona Central	TM
	SPC27NY3	Sistema Plano de Coordenadas del Estado de Nueva York Zona Oeste	TM
	SPC27NY4	Sistema Plano de Coordenadas del Estado de Nueva York Zona de Long Island	L
Ohio	SPC27OH1	Sistema Plano de Coordenadas del Estado de Ohio Zona Norte	L
	SPC27OH2	Sistema Plano de Coordenadas del Estado de Ohio Zona Sur	L
Oklahoma	SPC27OK1	Sistema Plano de Coordenadas del Estado de Oklahoma Zona Norte	L
	SPC27OK2	Sistema Plano de Coordenadas del Estado de Oklahoma Zona Sur	L
Oregon	SPC27OR1	Sistema Plano de Coordenadas del Estado de Oregon Zona Norte	L
	SPC27OR2	Sistema Plano de Coordenadas del Estado de Oregon Zona Sur	L
Pennsylvania	SPC27PA1	Sistema Plano de Coordenadas del Estado de Pennsylvania Zona Norte	L
	SPC27PA2	Sistema Plano de Coordenadas del Estado de Pennsylvania Zona Sur	L
Puerto Rico & Islas Vírgenes	SPC27PR1	Sistema Plano de Coordenadas del Estado de Puerto Rico & las Islas Vírgenes Zona 1	L
	SPC27PR2	Sistema Plano de Coordenadas del Estado de Puerto Rico & las Islas Vírgenes Zona 2 (St. Croix)	L
Rhode Island	SPC27RI1	Sistema Plano de Coordenadas del Estado de Rhode Island Zona 1	TM
Samoa	-ninguno-	-no avalado-	L
Carolina del Sur	SPC27SC1	Sistema Plano de Coordenadas del Estado de Carolina del Sur Zona Norte	L
	SPC27SC2	Sistema Plano de Coordenadas del Estado de Carolina del Sur Zona Sur	L
Dakota del Sur	SPC27SD1	Sistema Plano de Coordenadas del Estado de Dakota del Sur Zona Norte	L
	SPC27SD2	Sistema Plano de Coordenadas del Estado de Dakota del Sur Zona Sur	L

Estado	Nombre del Archivo	Título	Proyección
Tennessee	SPC27TN1	Sistema Plano de Coordenadas del Estado de Tennessee Zona 1	L
Tejas	SPC27TX1	Sistema Plano de Coordenadas del Estado de Tejas Zona Norte	L
	SPC27TX2	Sistema Plano de Coordenadas del Estado de Tejas Zona Central Norte	L
	SPC27TX3	Sistema Plano de Coordenadas del Estado de Tejas Zona Central	L
	SPC27TX4	Sistema Plano de Coordenadas del Estado de Tejas Zona Central Sur	L
	SPC27TX5	Sistema Plano de Coordenadas del Estado de Tejas Zona Sur	L
Utah	SPC27UT1	Sistema Plano de Coordenadas del Estado de Utah Zona Norte	L
	SPC27UT2	Sistema Plano de Coordenadas del Estado de Utah Zona Central	L
	SPC27UT3	Sistema Plano de Coordenadas del Estado de Utah Zona Sur	L
Vermont	SPC27VT1	Sistema Plano de Coordenadas del Estado de Vermont Zona 1	TM
Virginia	SPC27VA1	Sistema Plano de Coordenadas del Estado de Virginia Zona Norte	L
	SPC27VA2	Sistema Plano de Coordenadas del Estado de Virginia Zona Sur	L
Virginia Occidental	SPC27WV1	Sistema Plano de Coordenadas del Estado de Virginia Occidental Zona Norte	L
	SPC27WV2	Sistema Plano de Coordenadas del Estado de Virginia Occidental Zona Sur	L
Washington	SPC27WA1	Sistema Plano de Coordenadas del Estado de Washington Zona Norte	L
	SPC27WA2	Sistema Plano de Coordenadas del Estado de Washington Zona Sur	L
Wisconsin	SPC27WI1	Sistema Plano de Coordenadas del Estado de Wisconsin Zona Norte	L
	SPC27WI2	Sistema Plano de Coordenadas del Estado de Wisconsin Zona Central	L
	SPC27WI3	Sistema Plano de Coordenadas del Estado de Wisconsin Zona Sur	L
Wyoming	SPC27WY1	Sistema Plano de Coordenadas del Estado de Wyoming Zona Este	TM
	SPC27WY2	Sistema Plano de Coordenadas del Estado de Wyoming Zona Central Este	TM
	SPC27WY3	Sistema Plano de Coordenadas del Estado de Wyoming Zona Central Oeste	TM
	SPC27WY4	Sistema Plano de Coordenadas del Estado de Wyoming Zona Oeste	TM

# Sistema Plano de Coordenadas de los Estados de Estados Unidos 1983

Hay archivos REF suministrados para todos los Sistemas Planos de Coordenadas de los Estados de Estados Unidos en las proyecciones Mercator Transversal y Cónica Conforme de Lambert para NAD27 y NAD83. Estos se encuentran en el subdirectorio del directorio del programa CartaLinx. La siguiente tabla especifica estos archivos para el datum NAD83. La columna *Proy* indica la proyección en la cual se basa el sistema (L=Lambert Conformal Conic / TM=Transverse Mercator). Observe que Samoa no realizó el cambio de NAD27 a NAD83.

Estado	Nombre del Archivo	Título	Proy.
Alabama	SPC83AL1	Sistema Plano de Coordenadas del Estado de Alabama Zona Este	TM
	SPC83AL2	Sistema Plano de Coordenadas del Estado de Alabama Zona Oeste	TM
Alaska	SPC83AK0	Sistema Plano de Coordenadas del Estado de Alaska Zona 10	TM
	SPC83AK2	Sistema Plano de Coordenadas del Estado de Alaska Zona 2	TM
	SPC83AK3	Sistema Plano de Coordenadas del Estado de Alaska Zona 3	TM
	SPC83AK4	Sistema Plano de Coordenadas del Estado de Alaska Zona 4	TM
	SPC83AK5	Sistema Plano de Coordenadas del Estado de Alaska Zona 5	TM
	SPC83AK6	Sistema Plano de Coordenadas del Estado de Alaska Zona 6	TM
	SPC83AK7	Sistema Plano de Coordenadas del Estado de Alaska Zona 7	TM
	SPC83AK8	Sistema Plano de Coordenadas del Estado de Alaska Zona 8	TM
	SPC83AK9	Sistema Plano de Coordenadas del Estado de Alaska Zona 9	TM
Arizona	SPC83AZ1	Sistema Plano de Coordenadas del Estado de Arizona Zona Este	TM
	SPC83AZ2	Sistema Plano de Coordenadas del Estado de Arizona Zona Central	TM
	SPC83AZ3	Sistema Plano de Coordenadas del Estado de Arizona Zona Oeste	TM
Arkansas	SPC83AR1	Sistema Plano de Coordenadas del Estado de Arkansas Zona Norte	L
	SPC83AR2	Sistema Plano de Coordenadas del Estado de Arkansas Zona Sur	L
California	SPC83CA1	Sistema Plano de Coordenadas del Estado de California Zona I	L
	SPC83CA2	Sistema Plano de Coordenadas del Estado de California Zona II	L
	SPC83CA3	Sistema Plano de Coordenadas del Estado de California Zona III	L
	SPC83CA4	Sistema Plano de Coordenadas del Estado de California Zona IV	L
	SPC83CA5	Sistema Plano de Coordenadas del Estado de California Zona V	L
	SPC83CA6	Sistema Plano de Coordenadas del Estado de California Zona VI	L
Colorado	SPC83CO1	Sistema Plano de Coordenadas del Estado de Colorado Zona Norte	L
	SPC83CO2	Sistema Plano de Coordenadas del Estado de Colorado Zona Central	L
	SPC83CO3	Sistema Plano de Coordenadas del Estado de Colorado Zona Sur	L
Connecticut	SPC83CT1	Sistema Plano de Coordenadas del Estado de Connecticut Zona 1	L
Delaware	SPC83DE1	Sistema Plano de Coordenadas del Estado de Delaware Zona 1	TM
Florida	SPC83FL1	Sistema Plano de Coordenadas del Estado de Florida Zona Este	TM
	SPC83FL2	Sistema Plano de Coordenadas del Estado de Florida Zona Oeste	TM
	SPC83FL3	Sistema Plano de Coordenadas del Estado de Florida Zona Norte	TM
Georgia	SPC83GA1	Sistema Plano de Coordenadas del Estado de Georgia Zona Este	TM
	SPC83GA2	Sistema Plano de Coordenadas del Estado de Georgia Zona Oeste	TM

Estado	Nombre del archivo	Título	Proy.
Hawaii	SPC83HI1	Sistema Plano de Coordenadas del Estado de Hawaii Zona Zona 1	TM
	SPC83HI2	Sistema Plano de Coordenadas del Estado de Hawaii Zona Zona 2	TM
	SPC83HI3	Sistema Plano de Coordenadas del Estado de Hawaii Zona Zona 3	TM
	SPC83HI4	Sistema Plano de Coordenadas del Estado de Hawaii Zona Zona 4	TM
	SPC83HI5	Sistema Plano de Coordenadas del Estado de Hawaii Zona Zona 5	TM
Idaho	SPC83ID1	Sistema Plano de Coordenadas del Estado de Idaho Zona Este	TM
	SPC83ID2	Sistema Plano de Coordenadas del Estado de Idaho Zona Central	TM
	SPC83ID3	Sistema Plano de Coordenadas del Estado de Idaho Zona Oeste	TM
Illinois	SPC83IL1	Sistema Plano de Coordenadas del Estado de Illinois Zona Este	TM
	SPC83IL2	Sistema Plano de Coordenadas del Estado de Illinois Zona Oeste	TM
Indiana	SPC83IN1	Sistema Plano de Coordenadas del Estado de Indiana Zona Este	TM
	SPC83IN2	Sistema Plano de Coordenadas del Estado de Indiana Zona Oeste	TM
Iowa	SPC83IA1	Sistema Plano de Coordenadas del Estado de Iowa Zona Norte	L
	SPC83IA2	Sistema Plano de Coordenadas del Estado de Iowa Zona Sur	L
Kansas	SPC83KS1	Sistema Plano de Coordenadas del Estado de Kansas Zona Norte	L
	SPC83KS2	Sistema Plano de Coordenadas del Estado de Kansas Zona Sur	L
Kentucky	SPC83KY1	Sistema Plano de Coordenadas del Estado de Kentucky Zona Norte	L
	SPC83KY2	Sistema Plano de Coordenadas del Estado de Kentucky Zona Sur	L
Louisiana	SPC83LA1	Sistema Plano de Coordenadas del Estado de Louisiana Zona Norte	L
	SPC83LA2	Sistema Plano de Coordenadas del Estado de Louisiana Zona Sur	L
	SPC83LA3	Sistema Plano de Coordenadas del Estado de Louisiana Zona Alta Mar	L
Maine	SPC83ME1	Sistema Plano de Coordenadas del Estado de Maine Zona Este	TM
	SPC83ME2	Sistema Plano de Coordenadas del Estado de Maine Zona Oeste	TM
Maryland	SPC83MD1	Sistema Plano de Coordenadas del Estado de Maryland Zona 1	L
Massachusetts	SPC83MA1	Sistema Plano de Coordenadas del Estado de Massachusetts Zona Continental	L
	SPC83MA2	Sistema Plano de Coordenadas del Estado de Massachusetts Zona Insular	L
Michigan	SPC83MI1	Actual Sistema Plano de Coordenadas del Estado de Michigan Zona Norte	L
	SPC83MI2	Actual Sistema Plano de Coordenadas del Estado de Michigan Zona Central	L
	SPC83MI3	Actual Sistema Plano de Coordenadas del Estado de Michigan Zona Sur	L
	SPC83MI4	Viejo Sistema Plano de Coordenadas del Estado de Michigan Zona Este	TM
	SPC83MI5	Viejo Sistema Plano de Coordenadas del Estado de Michigan Zona Central	TM
	SPC83MI6	Viejo Sistema Plano de Coordenadas del Estado de Michigan Zona Oeste	TM



Estado	Nombre del Archivo	Título	Proy.
Minnesota	SPC83MN1	Sistema Plano de Coordenadas del Estado de Minnesota Zona Norte	L
	SPC83MN2	Sistema Plano de Coordenadas del Estado de Minnesota Zona Central	L
	SPC83MN3	Sistema Plano de Coordenadas del Estado de Minnesota Zona Sur	L
Mississippi	SPC83MS1	Sistema Plano de Coordenadas del Estado de Mississippi Zona Este	TM
	SPC83MS2	Sistema Plano de Coordenadas del Estado de Mississippi Zona Oeste	TM
Missouri	SPC83MO1	Sistema Plano de Coordenadas del Estado de Missouri Zona Este	TM
	SPC83MO2	Sistema Plano de Coordenadas del Estado de Missouri Zona Central	TM
	SPC83MO3	Sistema Plano de Coordenadas del Estado de Missouri Zona Oeste	TM
Montana	SPC83MT1	Sistema Plano de Coordenadas del Estado de Montana Zona Unica	L
Nebraska	SPC83NE1	Sistema Plano de Coordenadas del Estado de Nebraska Zona Unica	L
Nevada	SPC83NV1	Sistema Plano de Coordenadas del Estado de Nevada Zona Este	TM
	SPC83NV2	Sistema Plano de Coordenadas del Estado de Nevada Zona Central	TM
	SPC83NV3	Sistema Plano de Coordenadas del Estado de Nevada Zona Oeste	TM
Nueva Hampshire	SPC83NH1	Sistema Plano de Coordenadas del Estado de Nueva Hampshire Zona 1	TM
Nueva Jersey	SPC83NJ1	Sistema Plano de Coordenadas del Estado de Nueva Jersey Zona 1	TM
Nuevo México	SPC83NM1	Sistema Plano de Coordenadas del Estado de Nuevo México Zona Este	TM
	SPC83NM2	Sistema Plano de Coordenadas del Estado de Nuevo México Zona Central	TM
	SPC83NM3	Sistema Plano de Coordenadas del Estado de Nuevo México Zona Oeste	TM
Nueva York	SPC83NY1	Sistema Plano de Coordenadas del Estado de Nueva York Zona Este	TM
	SPC83NY2	Sistema Plano de Coordenadas del Estado de Nueva York Zona Central	TM
	SPC83NY3	Sistema Plano de Coordenadas del Estado de Nueva York Zona Oeste	TM
	SPC83N Y 4	Sistema Plano de Coordenadas del Estado de Nueva York Zona de Long Island	L
Ohio	SPC83OH1	Sistema Plano de Coordenadas del Estado de Ohio Zona Norte	L
	SPC83OH2	Sistema Plano de Coordenadas del Estado de Ohio Zona Sur	L
Oklahoma	SPC83OK1	Sistema Plano de Coordenadas del Estado de Oklahoma Zona Norte	L
	SPC83OK2	Sistema Plano de Coordenadas del Estado de Oklahoma Zona Sur	L
Oregon	SPC83OR1	Sistema Plano de Coordenadas del Estado de Oregon Zona Norte	L

Estado	Nombre del Archivo	Título	Proy.
	SPC83OR2	Sistema Plano de Coordenadas del Estado de Oregon Zona Sur	L
Pennsylvania	SPC83PA1	Sistema Plano de Coordenadas del Estado de Pennsylvania Zona Norte	L
	SPC83PA2	Sistema Plano de Coordenadas del Estado de Pennsylvania Zona Sur	L
Puerto Rico & Islas Vírgenes	SPC83PR1	Sistema Plano de Coordenadas del Estado de Puerto Rico & las Islas Vírgenes Zona 1	L
	SPC83PR2	Sistema Plano de Coordenadas del Estado de Puerto Rico & las Islas Vírgenes Zona 2 (St. Croix)	L
Rhode Island	SPC83RI1	Sistema Plano de Coordenadas del Estado de Rhode Island Zona 1	TM
Samoa	-ninguno-	-no avalado-	L
Carolina del Sur	SPC83SC1	Sistema Plano de Coordenadas del Estado de Carolina del Sur Zona 1 Zona Unica	
Dakota del Sur	SPC83SD1	Sistema Plano de Coordenadas del Estado de Dakota del Sur Zona Norte	
	SPC83SD2	Sistema Plano de Coordenadas del Estado de Dakota del Sur Zona Sur	
Tennessee	SPC83TN1	Sistema Plano de Coordenadas del Estado de Tennessee Zona 1	L
Texas	SPC83TX1	Sistema Plano de Coordenadas del Estado de Tejas Zona Norte	L
	SPC83TX2	Sistema Plano de Coordenadas del Estado de Tejas Zona Central Norte	L
	SPC83TX3	Sistema Plano de Coordenadas del Estado de Tejas Zona Central	L
	SPC83TX4	Sistema Plano de Coordenadas del Estado de Tejas Zona Central Sur	L
	SPC83TX5	Sistema Plano de Coordenadas del Estado de Tejas Zona Sur	L
Utah	SPC83UT1	Sistema Plano de Coordenadas del Estado de Utah Zona Norte	L
	SPC83UT2	Sistema Plano de Coordenadas del Estado de Utah Zona Central	L
	SPC83UT3	Sistema Plano de Coordenadas del Estado de Utah Zona Sur	L
Vermont	SPC83VT1	Sistema Plano de Coordenadas del Estado de Vermont Zona 1	TM
Virginia	SPC83VA1	Sistema Plano de Coordenadas del Estado de Virginia Zona Norte	L
	SPC83VA2	Sistema Plano de Coordenadas del Estado de Virginia Zona Sur	L
Virginia Occidental	SPC83WV1	Sistema Plano de Coordenadas del Estado de Virginia Occidental Zona Norte	L
	SPC83WV2	Sistema Plano de Coordenadas del Estado de Virginia Occidental Zona Sur	L
Washington	SPC83WA1	Sistema Plano de Coordenadas del Estado de Washington Zona Norte	L
	SPC83WA2	Sistema Plano de Coordenadas del Estado de Washington Zona Sur	L
Wisconsin	SPC83WI1	Sistema Plano de Coordenadas del Estado de Wisconsin Zona Norte	L
	SPC83WI2	Sistema Plano de Coordenadas del Estado de Wisconsin Zona Central	L
	SPC83WI3	Sistema Plano de Coordenadas del Estado de Wisconsin Zona Sur	L
Wyoming	SPC83WY1	Sistema Plano de Coordenadas del Estado de Wyoming Zona Este	TM
	SPC83WY2	Sistema Plano de Coordenadas del Estado de Wyoming Zona Central Este	TM
	SPC83WY3	Sistema Plano de Coordenadas del Estado de Wyoming Zona Central Oeste	TM
	SPC83WY4	Sistema Plano de Coordenadas del Estado de Wyoming Zona Oeste	TM

## Gauss-Kruger

El sistema de referencia Gauss-Kruger se usa principalmente en los países de la antigua Unión Soviética y el Bloque Este. Se incluyen archivos REF para las zonas 1 a 32. Todos usan el datum Pulkovo 1942 y el elipsoide *Krassovsky* 1940. Los nombres de estos archivos son GK01\_P42.ref hasta GK32\_P42.ref. La proyección Gauss-Kruger es idéntica a la proyección Mercator Transversal. (Observe que la forma alternativa de escribir “Gauss-Krueger” también es aceptable en un archivo REF.)

## Misceláneo

Tenga en cuenta que IDRISI también incluye archivos variados del sistema de referencia regional y local. Puede hallarse una lista de estos archivos dentro de IDRISI Help System (Sistema de Ayuda de IDRISI), en la sección Notes del módulo PROJECT.

# APÉNDICE 4: Fórmulas de Propagación de Errores

## Operaciones Aritméticas

En las siguientes fórmulas, S se refiere al error RMS. Se presentan fórmulas para cada una de las operaciones aritméticas realizadas por los módulos OVERLAY y SCALAR de IDRISI. En las operaciones de OVERLAY,  $S_x$  se refiere al error RMS en el Mapa X,  $S_y$  se refiere al error RMS en el Mapa Y, y  $S_z$  se refiere al error RMS en el Mapa Z. En las operaciones de SCALAR, K se refiere a una constante definida por el usuario. A menudo, el error es computado como un valor uniforme para todo el mapa resultante. Sin embargo, en algunos casos, la fórmula depende de los valores en las celdas correspondientes del mapa de entrada. Estas son referidas como X e Y. En estas ocasiones, el error puede variar en la cara de un mapa y, por lo tanto, necesita ser computado en forma separada para cada celda. Observe que estas fórmulas suponen que los mapas de entrada no están correlacionados unos con otros.

Suma / Sustracción en Overlay

(Ej.:  $Z=X+Y$  ó  $Z=X-Y$ ) 
$$S_z = \sqrt{S_x^2 + S_y^2}$$

Multipliación /División en Overlay

(Ej.:  $Z=X*Y$  ó  $Z=X/Y$ ) 
$$S_z = \sqrt{(S_x^2 \cdot Y^2 + (S_y^2 \cdot X^2))}$$

Suma / Sustracción en Scalar

(Ej.:  $Z=X+k$  ó  $Z=X-k$ )  $S_z = S_x$  *es decir, no hay cambio*

Multipliación en Scalar

(Ej.:  $Z=X*k$ )  $S_z = S_x * k$

División en Scalar

(Ej.:  $Z=X/k$ )  $S_z = S_x / k$

Exponente en Scalar

(Ej.:  $Z=X^k$ ) 
$$S_z = \sqrt{k^2 \cdot X^{2(k-1)} \cdot S_x^2}$$

## Operaciones Lógicas

Para las operaciones booleanas, los errores lógicos pueden estar expresados por la proporción de celdas que se espera tengan error ( $e$ ) en la categoría superpuesta. Como una supercapa booleana requiere dos mapas de entrada, el error del mapa de salida será una función de los errores de los dos mapas de entrada y la operación lógica realizada es la siguiente:

AND Lógico

$e_z = e_x + (1 - e_x) * e_y$  o de manera equivalente  $e_z = e_x + e_y - (e_x * e_y)$

OR Lógico

$e_z = e_x * e_y$