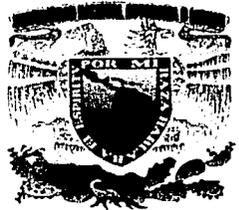


01132
66

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERIA

**EVALUACIÓN DE MÉTODOS DE CLASIFICACIÓN POR CONTEXTO
DE IMÁGENES MULTI ESPECTRALES SOBRE UN AREA
URBANA**



T E S I S
QUE PARA OBTENER EL TÍTULO DE:
INGENIERO EN COMPUTACIÓN

P R E S E N T A :
CONRADO MONTEALEGRE CÁZARES

DIRECTOR:
DRA. ROSA MARÍA PROL LEDESMA





Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

PAGINACIÓN DISCONTINUA

AGRADECIMIENTOS

A la vida.

A mis padres por todo su apoyo incondicional y también por confiar en mí con la mezcla perfecta de exigencia y condescendencia.

A mi hermano por aceptarme tal y como soy, y por estar ahí siempre que lo necesito.

A la UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO por la grandiosa formación que recibí en todos los aspectos.

A la Dra. Rosa María Prol Ledesma por la guía y apoyo que me brindó en todo momento de la elaboración de esta tesis.

A mi familia por brindarme siempre todo su amor.

A Isa por impulsarme siempre a ser mejor.

A mis amigos por brindarme su tiempo y cariño.

DEDICATORIA

Dedico este trabajo y todo lo que representa a mis padres, pues con su apoyo, y cada uno con su forma de ser, han representado siempre la cosa más valiosa que tengo, así como mi guía y ejemplo a seguir.

También lo dedico a mi hermano Marco, que siempre ha sido la alegría de mi vida y mi inyección de vitalidad.

Por último, y no por esto menos importante, a todas las personas que han influido en mi vida: a ti Isa que has representado siempre una inspiración y apoyo en todas mis acciones, así como un ejemplo a seguir; a mis padrinos Bayo y Carmelita que siempre me han apoyado, así como a mis primos a los cuales siempre he considerado mis hermanos; a toda mi familia por parte de mi mamá con la cual me siento siempre muy cómodo, seguro y amado; a mis abuelitos a quienes quiero muchísimo; y a mis amigos Delfino, Víctor, Pato, Fabián, Quique, Raulju y todos los Multimedia.

TESIS CON FALLA
DE
ORIGEN

ÍNDICE

1. INTRODUCCIÓN	1
1.1 Definición del problema	1
1.2 Método	3
2. CONCEPTOS BÁSICOS	5
2.1 Percepción Remota	5
2.1.1 Definición y objetivos	5
2.1.2 Historia	6
2.1.3 Aplicaciones principales	8
2.2 Fundamentos de la Percepción Remota.	9
2.3 Espectro electromagnético	11
2.4 Principios y leyes de la radiación electromagnética	13
2.5 Dominio óptico del espectro	15
2.5.1 Características de la vegetación en el espectro óptico	21
2.5.2 Características del suelo en el espectro óptico	23
2.5.3 Características del agua en el espectro óptico	25
2.6 Fuentes de imágenes de Percepción Remota	26
2.6.1 Resolución de un sistema sensor	27
2.6.1.1 Resolución espacial	27
2.6.1.2 Resolución espectral	28
2.6.1.3 Resolución radiométrica	29
2.6.1.4 Resolución temporal	29
2.6.2 Satélites climáticos	30
2.6.3 Satélites de recursos naturales	32
2.6.3.1 LANDSAT	32
2.6.3.2 SPOT	38
2.6.3.3 Skylab	39
2.6.3.4 MOS	40
3. PROCESAMIENTO DIGITAL DE LA IMAGEN	41
3.1 Formatos de datos de una imagen digital	41
3.2 Consideraciones de un sistema de procesamiento digital de imágenes multispectrales	44
3.2.1 Hardware	45
3.2.2 Software	46
3.3 Cálculo de estadísticas de la imagen	47
3.3.1 Histograma de la imagen	48
3.3.2 Estadísticas <i>univariable</i> de la imagen	50
3.3.3 Estadísticas multivariable de la imagen	52
3.4 Despliegue de imágenes multispectrales	56
3.4.1 Mapas de brillantez blanco-negro y color	57
3.4.2 Composiciones en color	61
3.5 Realce de la imagen	62
3.5.1 Cambios de escala	62
3.5.2 Realce del contraste	64
3.5.2.1 Realce lineal del contraste	69

3.5.2.2 Realce lineal del contraste con saturación	71
3.5.2.3 Realce del contraste logarítmico y exponencial	72
3.5.2.4 Ecuilización del histograma	72
3.5.3 Filtros espaciales	76
3.5.3.1 Naturaleza de un filtro digital espacial	76
3.5.3.2 Filtros pasa bajas	78
3.5.3.3 Filtros pasa altas	79
3.6 Transformaciones multiespectrales de la imagen	82
3.6.1 Análisis de componentes principales (PCA)	82
4. CLASIFICACIÓN DE IMÁGENES MULTIESPECTRALES	88
4.1 Clasificación supervisada	92
4.1.1 Clasificación por mínima distancia	96
4.1.2 Clasificación por paralelepípedo	98
4.1.3 Clasificación por máxima verosimilitud	99
4.2 Clasificación no supervisada	104
4.3 Clasificación por contexto	107
5. APLICACIÓN PRÁCTICA	111
6. COMPARACIÓN Y EVALUACIÓN DE RESULTADOS	137
6.1 Bases teóricas	137
6.2 Evaluación de la aplicación práctica	143
7. CONCLUSIONES	148
BIBLIOGRAFÍA CONSULTADA Y REFERENCIAS	150
APÉNDICE 1. CORRECCIÓN ATMOSFÉRICA	152

TESIS CON
 FALLA DE ORIGEN

1. INTRODUCCIÓN

1.1 Definición del problema

En la actualidad, gracias al desarrollo de las ciencias computacionales y de las telecomunicaciones, se ha extendido el uso de imágenes satelitales para el estudio de nuestro planeta tierra.

Una de estas aplicaciones para el estudio de nuestro planeta, es precisamente el definir el uso del suelo en determinadas zonas. Es decir, se determina a partir de imágenes satelitales, el tipo de suelo del cual se trata en específico, o bien su uso. Por ejemplo, se determina si se trata de un campo de cultivo, un área boscosa, un área urbana densamente poblada, suelo desnudo, un lago, etc.

Para este fin, se ocupan regularmente las llamadas imágenes multispectrales, las cuales son imágenes obtenidas en múltiples regiones del espectro electromagnético de una zona en específico. Debido a que cada cubierta terrestre tiene un patrón específico de respuesta en cada banda del espectro electromagnético, se puede hacer la distinción de cada cubierta si en la banda o bandas utilizadas, existe el suficiente contraste entre cubierta y cubierta para lograr distinguir las entre sí.

Se han desarrollado muchos métodos para optimizar la obtención de información a partir de las imágenes multispectrales obtenidas por los satélites. Estos métodos se han dividido tradicionalmente en 2 grupos: clasificación supervisada y clasificación no supervisada.

Dentro de la clasificación supervisada se pueden identificar métodos como el de la máxima verosimilitud, de la mínima distancia o del paralelepípedo, los cuales han sido ampliamente utilizados. Estos métodos también son llamados métodos de clasificación por píxel, puesto que van analizando píxel por píxel para determinar a que categoría corresponde cada uno de estos. También podemos encontrar métodos más avanzados como los clasificadores de contexto, clasificadores que usan redes neuronales o clasificadores que usan lógica difusa, entre otros.

Obviamente, cada método tiene sus ventajas y desventajas en función de la facilidad y conveniencia en la implementación, y de la exactitud en los resultados de la clasificación. Para poder elegir que método es más conveniente ocupar, se deben tener en cuenta los medios con los que se cuenta, qué tipo de terreno es el que se va a estudiar y qué tipo de información predominantemente se espera obtener.

Generalmente los métodos de clasificación por píxel arrojan buenos resultados, equilibrando la facilidad en la implementación y la exactitud de los resultados. Específicamente, el método de la máxima verosimilitud nos da una clasificación muy exacta, además este método es ampliamente usado en los distintos programas de análisis de datos

TESIS COM
FALLA DE ORIGEN

geográficos, lo cual lo hace uno de los métodos más utilizados en la práctica. Sin embargo, los resultados de este método en áreas que no resultan ser muy homogéneas en su composición suelen lucir comúnmente muy fragmentados, es decir, manchas más o menos homogéneas de un color se encuentran salpicadas por píxeles asignados a otras categorías. Este efecto, en la literatura anglosajona, se le llama coloquialmente de "sal y pimienta" (*salt and pepper*). En los casos de imágenes que presentan grandes áreas urbanas este efecto es muy común e incluso representa una forma de ruido el cual es preciso eliminar, o por lo menos minimizar sus efectos.

Para corregir este problema, se ha recurrido a métodos de clasificación más elaborados, o incluso a la mezcla de varios de estos. Una de las metodologías que ha probado ser bastante eficiente para disminuir este problema, sobre todo en áreas urbanas, es la de los clasificadores por contexto, pues al tomar en cuenta los píxeles aledaños al píxel que se analiza y no sólo al píxel en cuestión, tienden de forma natural a dar como resultado áreas de clasificación más homogéneas. Además, se ha comprobado que estos métodos no resultan tan complicados en su implementación, como lo serían los clasificadores que usan redes neuronales o lógica difusa, que si bien arrojan en general mejores resultados, el exceso en su complejidad y en su gasto de recursos computacionales, los hace no ser tan eficientes como los clasificadores por contexto.

Si bien se han comprobado ya las ventajas de usar clasificadores por contexto para mejorar los resultados en el estudio de áreas urbanas en otras partes del mundo, resulta particularmente importante hacer estas pruebas en áreas urbanas de nuestro país. Las condiciones específicas de cada zona son irrepetibles, lo cual hace que técnicas que son útiles en un lugar, puedan no serlo en otro.

Es precisamente bajo este contexto, que se desarrolla la idea de realizar este trabajo. En primer lugar, se pretende describir detalladamente los métodos de clasificación tradicionalmente usados, así como algunos métodos de clasificación por contexto. Para completar esta descripción, es importante incluir las bases teóricas necesarias para entender con la profundidad debida, los conceptos de percepción remota y procesamiento digital de imágenes que se requieren para un completo entendimiento. Por otro lado, se aplicarán los métodos descritos sobre un área urbana mexicana, para poder evaluar su aplicación y resultados. Con este fin se ha decidido utilizar imágenes satelitales de una parte del área urbana de Guadalajara, la cual incluye otros tipos de cubiertas, y no solo área urbana, puesto que también es importante evaluar estas técnicas sobre distintos tipos de cubiertas.

Después de plantear el proyecto, se entiende la importancia de éste, pues por un lado se pretende probar y evaluar en nuestro país técnicas usadas en otras partes del mundo, y que han ya probado ser de gran utilidad. Por otro lado, se pretende dar una detallada descripción de los pasos a seguir (tanto en el estudio del tema como en el desarrollo de este) para clasificar imágenes multiespectrales. Esta descripción se hará siempre bajo el enfoque principal de las ciencias computacionales, pero sin perder de vista la importancia del contexto del área específica de aplicación de estas técnicas.

Si bien este trabajo se enfocará en la aplicación y evaluación de resultados para determinar el uso del suelo, y con este fin, se usarán imágenes satelitales; las técnicas y metodologías que serán descritas, se pueden ocupar para obtener resultados en diversas áreas

del conocimiento, como lo son la geología, geofísica, etc. Además estas técnicas no son de aplicación exclusiva a imágenes satelitales, si no que se pueden aplicar a imágenes de distintas fuentes como los son fotografías aéreas, imágenes del espacio exterior, imágenes de microscopio, etc.

1.2 Método

Ya se ha mencionado que existen varios métodos que pueden usarse para la clasificación de imágenes multispectrales. También se ha mencionado que la efectividad de los métodos depende mucho de las características de la zona de estudio, así como de los resultados que se pretendan obtener.

Los métodos que pueden aplicarse se pueden dividir, en una primera instancia, en clasificación supervisada y clasificación no supervisada. La clasificación no supervisada no requiere de un conocimiento profundo de la zona que se va a estudiar, pues consiste prácticamente en adquirir las imágenes, realizar un pre-procesamiento correcto, y aplicarle a éstas alguno de los algoritmos de clasificación no supervisada. Si bien se tiene la ventaja de que este método es muy sencillo y no requiere básicamente ningún conocimiento previo de la zona de estudio, los resultados que arroja no siempre son muy exactos, y mucho menos en zonas urbanas.

Por otro lado, las metodologías supervisadas, requieren de un conocimiento previo de la zona para poder determinar las "zonas de entrenamiento". Estas zonas de entrenamiento se obtienen a partir de estudios previamente realizados en una pequeña parte de la zona a estudiarse, donde se sabe de antemano que tipo de cubierta es la que se está observando en esa parte de la imagen. Esto se logra obteniendo información de mapas existentes, o bien de imágenes con mayor resolución, como lo podrían ser fotografías aéreas. Una vez que se tienen definidos los tipos de cubierta y en que parte de la imagen se logran ver más claramente, se "marcan" éstos, y se utilizan para conformar las "firmas" o "patrones" espectrales, los cuales servirán posteriormente para realizar la clasificación, pues los restantes píxeles de la imagen se irán asociando a alguna de estas firmas o patrones, según sea el método específico.

Ya se ha mencionado también, que existen dentro de la clasificación supervisada varios caminos para realizar la clasificación. Están los métodos de clasificación por píxel, llamados así porque determinan a que categoría pertenece cada píxel, analizando sólo a éste con respecto a las características de una firma espectral. Dentro de estos métodos está el método del paralelepípedo, el de mínima distancia y el de máxima verosimilitud. Este último es el que más extensamente se usa, pues combina la facilidad en la aplicación con la obtención en general de buenos resultados. La popularidad de este método ha hecho que sirva por lo regular como punto de referencia para probar otros métodos. Sin embargo este método presenta problemas en zonas urbanas grandes, pues la naturaleza poco homogénea de estas hace que los resultados se presenten salpicados o con el ya anteriormente descrito efecto de "sal y pimienta".

TESIS CON
FALLA DE ORIGEN

Se ha comprobado que tanto los métodos de clasificación por contexto, como los métodos que usan redes neuronales, mejoran sustancialmente la calidad de la clasificación en áreas urbanas. Sin embargo, el uso de redes neuronales implica un gasto en recursos computacionales y una mayor complejidad en su implementación. En contraparte, los clasificadores por contexto son generalmente muy sencillos, y no están muy por debajo de los de redes neuronales.

En este trabajo, se ha decidido probar la utilidad de métodos de clasificación por contexto, debido a que combinan la facilidad en la implementación con los buenos resultados. Por otro lado, se pretende también comparar los resultados obtenidos, con el método de máxima verosimilitud.

Para realizar esta comparación, el camino más comúnmente utilizado, es el de ver la exactitud con la cual cada método hace corresponder los píxeles a cada categoría, sirviendo de base de comparación información fiable de pequeñas zonas, obtenida de otras fuentes.

Antes de llegar a la aplicación de los algoritmos de clasificación, se deben aplicar técnicas de procesado a las imágenes, siempre en consideración a las necesidades propias de estas. Por ejemplo es muy común, hacer composiciones de falso color, con las distintas bandas espectrales de la imagen, para así mejorar el entendimiento de la zona, o bien para facilitar las zonas de entrenamiento. También, se puede trabajar con la transformación de principales componentes, para así eliminar la redundancia en la información. En otras ocasiones la imagen necesita ser corregida geoméricamente, o en su contraste o nitidez, para esto se le aplican filtros u otras técnicas según convenga. Por todo esto, es muy importante conocer de antemano la generalidad de opciones que existen, para así decidir sobre la marcha, y dependiendo las necesidades, que herramienta vamos a ocupar para mejorar la calidad de los resultados. Inclusive, para la presentación final, nos podemos valer de estas herramientas para facilitar el análisis de los resultados.

La finalidad de este trabajo no es programar los algoritmos que se vayan a utilizar, sino probar y evaluar su utilidad práctica sobre un área urbana. Por lo tanto se usarán los programas existentes para análisis geográfico, específicamente el IDRISI, el cual es un sistema de información geográfica y de procesamiento de imágenes, desarrollado por la Clark University Graduate School of Geography.

TESIS CON
FALLA DE ORIGEN

2. CONCEPTOS BÁSICOS

2.1 Percepción Remota

2.1.1 Definición y objetivos

El término Percepción Remota viene del término inglés *Remote Sensing*, el cual se utiliza desde mediados de los 60 para designar cualquier medio de observación remota.

Tenemos ahora que, si bien la observación remota de la superficie terrestre constituye el marco de estudio de la Percepción Remota, y que en sus inicios ésta se centró en las fotografías aéreas. En el presente trabajo me centraré en el estudio de imágenes obtenidas de satélites, si bien estas técnicas se pueden aplicar a imágenes obtenidas a partir de otras fuentes.

De forma particular, podemos definir la Percepción Remota como la técnica que permite obtener imágenes de la superficie terrestre desde sensores instalados en satélites (Chuvieco, 1990). Este estudio se basa en una interacción energética entre la tierra y el sensor, ya sea por reflexión de la energía solar o de un haz energético artificial. Además es importante mencionar que dentro del campo de estudio de la Percepción Remota se incluye también el análisis de la información recibida a través de este medio, aunque esté más allá de los procesos de adquisición propiamente dichos.

En un sistema de Percepción Remota se pueden distinguir los siguientes elementos (Fig. 2.1):

- i) Fuente de energía: es el origen del flujo energético detectado por el sensor. Esta fuente de energía puede provenir del mismo sensor, en cuyo caso hablaríamos de Percepción Remota activa, o de una fuente externa al sensor, la cual nos daría una Percepción Remota pasiva. Obviamente la fuente de energía más común es el Sol.
- ii) Cubierta terrestre: esta formada por distintas masas de vegetación, suelos, agua o construcciones humanas, que reciben la señal energética procedente de la fuente de energía y la reflejan o emiten de acuerdo a sus características físicas.
- iii) Sistema sensor: capta la energía procedente de las cubiertas terrestres, la codifica y graba, o bien la envía directamente al sistema de recepción.
- iv) Sistema de recepción-comercialización: es donde se recibe la información enviada por el sistema sensor, se graba en un formato apropiado, y después de realizar las correcciones necesarias, se distribuye entre los intérpretes-usuarios.
- v) Intérprete: analiza la información, ya sea en formato digital o analógico, convirtiéndola en una clave temática o cuantitativa, orientada a facilitar la evaluación del problema en estudio.
- vi) Usuario final: analiza el documento fruto de la interpretación y dictamina sobre las consecuencias que de él se deriven.

En la actualidad, el uso de los sistemas computacionales y sus técnicas, ha permitido la obtención, análisis y almacenamiento a gran escala de información obtenida por Percepción

Remota. Esto ha permitido mejorar la interpretación de esta información así como constituir Sistemas de Información Geográfica (GIS – por sus siglas en Inglés: Geographic Information Systems), los cuales permiten integrar gran cantidad de información que ha permitido mejorar el estudio de la tierra.

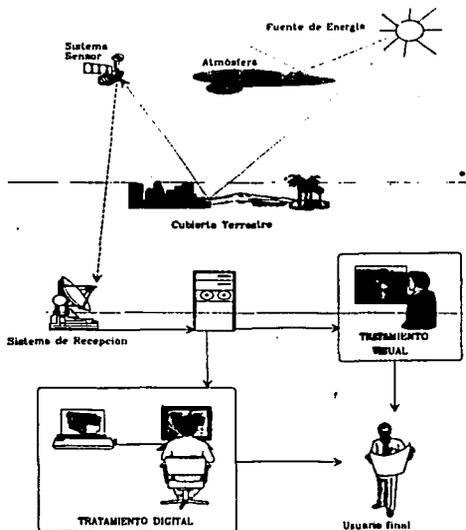


Fig. 2.1 Componentes de un sistema de Percepción Remota.

2.1.2 Historia

Debido a que la Percepción Remota es una técnica aplicada, ésta se ve afectada directamente con el estado del desarrollo tecnológico existente en cada momento. Tomando en cuenta que en esta se ven involucrados aspectos muy variados que van desde la óptica y detectores del sensor, vehículos que lo sustentan, hasta sistemas de transmisión y comercialización, etc., las formas de Percepción Remota han variado mucho a lo largo del tiempo.

Las primeras experiencias de Percepción Remota se remontan a 1859, cuando Gaspar Félix de Tournachon obtiene las primeras fotografías aéreas desde un globo estático. A su vez, James Wallace repite la experiencia al año siguiente sobre la ciudad de Boston, con esto se

comienza a observar la utilidad de una perspectiva aérea para un conocimiento más detallado de la organización urbana.

En los siguientes años, gracias al desarrollo en ópticas y emulsiones fotográficas, se observa un avance en la observación fotográfica desde avión. En 1909, Wilbur Wright realiza la primera fotografía aérea, y la primera cámara aérea se desarrolla en 1915 por J. T. C. Moore-Brabazon. Es en esta época, en el entorno de la Primera Guerra Mundial, cuando la importancia estratégica de este escrutinio queda en evidencia, incitándose así el desarrollo de las técnicas de adquisición y procesado fotográfico.

En la Segunda Guerra Mundial se produce un gran desarrollo en las técnicas de Percepción Remota aérea. Se mejora la óptica de las cámaras de reconocimiento y las emulsiones utilizadas en éstas. La *Kodak Research Laboratories* desarrolla las primeras películas en infrarrojo. También se introducen nuevos sensores como lo son el radar, se mejoran los sistemas de comunicación y, al mejorar la aeronáutica, se confiere mayor estabilidad a las plataformas de observación.

En los años de posguerra, todos estos adelantos se incorporan a aplicaciones civiles, mostrando su gran utilidad para mejorar el conocimiento y control de recursos naturales. A su vez, se mejoran los sistemas de radar, se introduce el sistema de radar lateral aerotransportado (SLAR) y se ponen a punto los sensores térmicos de barrido.

En los años 50, el desarrollo de los sistemas de navegación permite concebir los primeros ingenios espaciales, y alentados por la guerra fría, uno y otro bando realizan intensa investigación en este tema. Es en 1957 cuando los soviéticos logran poner en órbita su satélite llamado Sputnik. Este hecho fue seguido por una larga serie de misiones civiles y militares, lo cual permitió no solo la exploración de nuestro planeta, sino también de la Luna y los planetas vecinos.

Después de iniciada la carrera espacial, se pone de manifiesto la utilidad de usar estas plataformas espaciales para adquirir datos valiosos de la superficie y atmósfera terrestre. En 1960, la NASA pone en órbita el primer satélite de la serie TIROS, el cual es el pionero de múltiples misiones de observación meteorológica.

En 1961, durante una de las misiones del Mercury, Alan B. Shepard toma las primeras fotografías espaciales de una forma espontánea y un tanto rudimentaria. Si bien en las próximas misiones espaciales se continuaron tomando fotografías, no fue sino hasta el año de 1965, durante la misión Gemini-Titán, cuando se realizan los primeros experimentos formales de fotografía espacial, en este caso para usos geológicos y meteorológicos.

Debido a los buenos resultados obtenidos en estos primeros ensayos, la NASA continuó proyectando estas observaciones. En las misiones del Apollo-6 y Apollo-7 se adquieren diversas series de fotografías verticales. En 1969, en la misión del Apollo-9 se realiza el primer experimento multispectral, compuesto por cuatro cámaras Hasselblad con distintos filtros.

TESIS CON
FALLA DE ORIGEN

El 23 de julio de 1972, la NASA pone en órbita el primer satélite de la serie ERTS (*Earth Resources Technology Satellite*), el cual fue el primero dedicado exclusivamente a la cartografía y evaluación de los recursos naturales. Este proyecto, bautizado LANDSAT con la puesta en órbita del segundo satélite en 1975, se podría considerar como el más fructífero para las aplicaciones civiles de la Percepción Remota.

A la serie LANDSAT le siguieron otros proyectos específicamente diseñados para la observación medioambiental. Entre los más conocidos tenemos al laboratorio espacial tripulado Skylab (1973), al satélite oceanográfico Seasat (1978), al de investigación térmica HCMM (1978) -todos ellos propiedad de la NASA-, al satélite francés SPOT (1986), al japonés MOS-1 (1987), al indio IRS-1 (1988), a los rusos Soyuz y Salut, al proyecto europeo ERS-1 (1991), al japonés JERS-1 (1992) y al canadiense Radarsat (1994). También son importantes en este sentido, las numerosas misiones del transbordador espacial norteamericano *Space Shuttle*.

2.1.3 Aplicaciones principales

El uso de las técnicas de Percepción Remota es muy variado y se extiende a diversas áreas del conocimiento. A continuación se enumeran algunas de las principales aplicaciones, citadas en un informe sobre privatización del proyecto LANDSAT remitido al Congreso de los Estados Unidos (OTA, 1984):

- Estudio de la erosión de playas y arenales.
- Inventario regional del medio ambiente para preparar estudios de impactos ambientales.
- Cartografía geológica para la exploración mineral y petrolífera.
- Cartografía de nuevos depósitos volcánicos.
- Control de la acumulación pluvial, de la fusión y de los cambios previsibles en la disponibilidad de energía hidroeléctrica.
- Control del movimiento de *icebergs* en zonas polares.
- Estimación de modelos de escurrimiento y erosión.
- Inventario del agua superficial.
- Análisis en tiempo real de masas nubosas de escala media y pequeña.
- Medidas de aguas superficiales y humedales para evaluar la situación del hábitat para aves acuáticas.
- Verificación de contenidos de salinidad en las principales corrientes de agua.
- Cartografía térmica de la superficie del mar.
- Verificación y control de la calidad física del agua, turbidez y contenido de algas.
- Control de los movimientos de la *Corriente del Golfo* y otras corrientes marinas.
- Cartografía de la cobertura vegetal del suelo.
- Rápida evaluación de condiciones de estrés en la vegetación, por efectos de la sequía, la contaminación o deforestación.
- Cartografía de áreas quemadas y seguimiento de los ritmos de repoblación natural.
- Contribución a la cartografía e inventario de la cobertura y uso del suelo.

TESIS CON
FALLA DE ORIGEN

- Realización de inventarios forestales.
- Selección de rutas óptimas para nuevas vías de comunicación.
- Control de pastizales efímeros para estudiar efectos de la sequía y pastoreo excesivo.
- Cartografía e inventario de cultivos por especies.
- Predicción del rendimiento de cultivos.

Además de las aplicaciones anteriormente mencionadas, la Percepción Remota también se ha usado para estudios del espacio exterior.

2.2 Fundamentos de la Percepción Remota.

Anteriormente se definió la Percepción Remota como aquella técnica que permite obtener información a distancia de objetos situados sobre la superficie terrestre (Chuvieco, 1990). Para que esta observación sea posible, debe existir algún tipo de interacción entre los objetos y el sensor.

De los elementos que se mencionaron anteriormente como componentes de un sistema de Percepción Remota, tenemos que los más importantes son:

- i) Sensor.
- ii) Objeto observado.
- iii) Flujo energético.

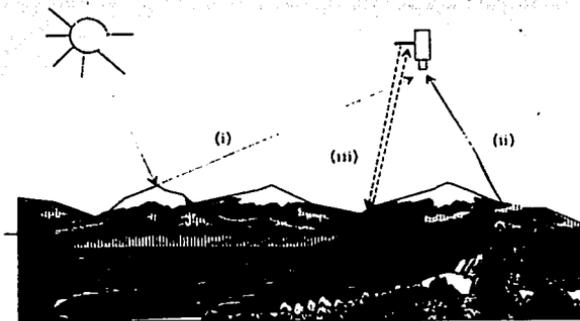


Fig. 2.2-Formas de Percepción Remota.

Para entender mejor este sistema podemos plantear como ejemplo el hecho de ver un árbol. En este caso el árbol es el objeto observado, nuestros ojos el sensor que recibe y traduce convenientemente una energía que pone en relación a ambos. Esta energía es el flujo energético, la cual podría tratarse de un tipo de energía emitida por el propio objeto, por una

fuerza externa o incluso por el mismo sensor. En el ejemplo del árbol, la fuente de energía no es generada por éste, si no que procede de un foco energético exterior que lo ilumina, de ahí que no seamos capaces de percibir el árbol en plena oscuridad.

Tenemos entonces tres formas de adquirir información a partir de un sensor remoto (Fig. 2.2):

- Por reflexión.
- Por emisión.
- Por emisión-reflexión.

De las tres, la primera es la más importante en la Percepción Remota, pues se deriva directamente de la luz solar, la cual es la principal fuente de energía en la superficie de nuestro planeta. El sol ilumina la superficie terrestre, que refleja esa energía en función del tipo de cubierta presente sobre ella. El sensor recoge ese flujo reflejado y posteriormente lo transmite a las estaciones receptoras. La Percepción Remota también se puede basar en la energía emitida por las propias cubiertas, o bien en la que se pudiese emitir un sensor capaz de generar su propio flujo energético y detectarlo después, posteriormente de su reflexión sobre la superficie terrestre.

En cualquiera de estos casos, el flujo energético entre la cubierta terrestre y el sensor constituye una forma de radiación electromagnética. Según la teoría ondulatoria, la energía electromagnética se transmite de un lugar a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y conteniendo dos campos de fuerzas ortogonales entre sí: eléctrico y magnético (Fig. 2.3).

Las características de este flujo energético se pueden describir por dos elementos:

- Longitud de onda (λ): distancia entre dos picos sucesivos de una onda.
- Frecuencia (F): el número de ciclos pasando por un punto fijo en una unidad de tiempo.

Ambos elementos están inversamente relacionados como se describe a continuación

$$c = \lambda F \quad [2.1]$$

donde c indica la velocidad de la luz (3×10^8 m/s), λ expresa la longitud de onda y F la frecuencia en Hertz (ciclos por segundo). Como se puede observar, a mayor longitud de onda menor frecuencia y viceversa, por lo tanto basta con indicar un solo término para identificar propiamente el tipo de energía mencionado.

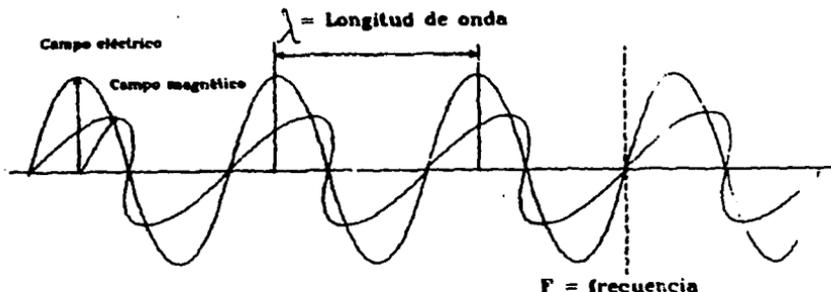


Fig. 2.3 Esquema de una onda electromagnética.

Gracias a la teoría cuántica podemos calcular la cantidad de energía transportada por un fotón, siempre que se conozca su frecuencia:

$$Q = h F \quad [2.2]$$

donde Q es la energía radiante de un fotón (en Jules), F la frecuencia y h la constante de Planck (6.6×10^{-34} J s). Si sustituimos la primera fórmula con la anterior, tenemos que

$$Q = h (c/\lambda) \quad [2.3]$$

lo que significa que a mayor longitud de onda, o menor frecuencia, el contenido energético será menor y viceversa.

2.3 Espectro electromagnético

De las fórmulas anteriores tenemos que, se puede describir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia. Si bien la sucesión de valores de longitud de onda es continua, suelen establecerse una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar. Se denomina espectro electromagnético a la organización de estas bandas de longitudes de onda o frecuencia (Fig. 2.4).

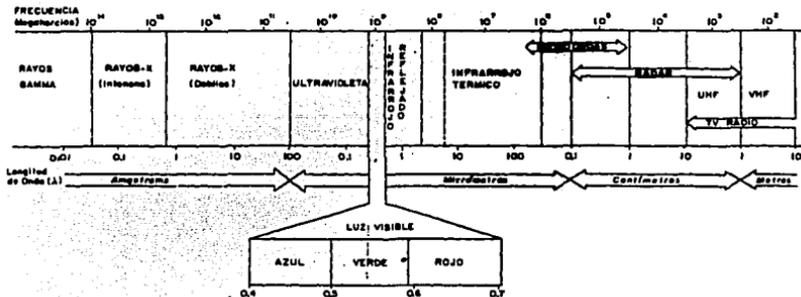


Fig. 2.4 Espectro electromagnético.

Desde el punto de vista de la Percepción Remota, conviene destacar una serie de bandas espectrales, que son las más frecuentemente empleadas con la tecnología actual:

- Espectro visible (0.4 a 0.7 μ m). Es la única radiación electromagnética que puede percibir nuestros ojos. Coincide con las longitudes de onda en donde es máxima la radiación solar. A su vez se distinguen tres bandas dentro de esta, en razón de los colores elementales asociados a esas longitudes de onda:
 - o Azul (0.4 a 0.5 μ m)
 - o Verde (0.5 a 0.6 μ m)
 - o Rojo (0.6 a 0.7 μ m)
- Infrarrojo cercano (0.7 a 1.3 μ m). Se denomina también infrarrojo reflejado y fotográfico. Resulta de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.
- Infrarrojo medio (1.3 a 8 μ m). En esta banda se entremezclan los procesos de reflexión de luz solar y de emisión de la superficie terrestre.
- Infrarrojo lejano o térmico (8 a 14 μ m). Incluye la porción emisiva del espectro terrestre.
- Microondas (a partir de 1 mm). Es de gran interés pues es un tipo de energía con capacidad de atravesar a la cubierta nubosa.

2.4 Principios y leyes de la radiación electromagnética

De acuerdo a la fórmula [2.3] la cantidad de energía que contiene un flujo radiante es inversamente proporcional a su longitud de onda. Esta relación de energía se puede establecer con más rigor gracias a la ley de Planck:

$$M_{n,\lambda} = \frac{2\pi hc^2}{\lambda^5 \{\exp(hc/\lambda kT) - 1\}} \quad [2.4]$$

donde $M_{n,\lambda}$ indica la emitancia radiativa espectral de un cuerpo negro a una determinada longitud de onda (λ); h es la constante de Planck ($6.626 \times 10^{-34} \text{ W s}^2$); k – la constante de Boltzman ($1.38 \times 10^{-23} \text{ W s}^2/\text{K}$); c , la velocidad de la luz; λ , la longitud de onda, y T la temperatura absoluta de un cuerpo negro (en Kelvin, K). Definiremos, a su vez, la emitancia radiante o radiativa (M) como el total de energía radiada en todas las direcciones desde una unidad de área y por unidad de tiempo, ésta se mide en Watts por metro cuadrado (W/m^2). Ahora bien, entenderemos por cuerpo negro a un emisor ideal, que radia el máximo de energía por unidad de superficie en cada longitud de onda y para una temperatura dada. Un cuerpo negro también absorbe toda la energía que sobre él incide.

La anterior fórmula [2.4] se puede simplificar sustituyendo algunos términos por constantes:

$$M_{n,\lambda} = \frac{c_1}{\lambda^5 \{\exp(c_2/\lambda T) - 1\}} \quad [2.5]$$

donde c_1 puede sustituirse por $3.74 \times 10^{-16} \text{ W m}^2$, y c_2 por $1.44 \times 10^2 \text{ m} \cdot \text{K}$.

La fórmula de Planck nos señala que cualquier objeto por encima del cero absoluto ($-273 \text{ }^\circ\text{C}$) radia energía, y que ésta se incrementa con la temperatura. A la vez, a mayor temperatura, ese cuerpo radiará con más intensidad en longitudes de onda más cortas.

A partir de la fórmula de Planck puede calcularse la longitud de onda a la que se produce la máxima emitancia de un cuerpo negro conociendo su temperatura (T) en Kelvin. Esta es la llamada ley del desplazamiento de Wien:

$$\lambda_{\max} = 2898 \mu\text{m K} / T \quad [2.6]$$

que tiene una gran importancia para seleccionar la banda más conveniente para detectar un determinado fenómeno, siempre que se conozca su temperatura. Por ejemplo, en el caso de los incendios forestales, teniendo en cuenta que la temperatura de combustión se sitúa entre 275 y $420 \text{ }^\circ\text{C}$, la ley de Wien nos permite situar entre 5.28 y $4.30 \mu\text{m}$ (infrarrojo medio) la banda espectral más adecuada para su detección.

Acumulando la emitancia espectral de un cuerpo negro para todas las longitudes de onda, podemos calcular el total de energía que radia por unidad de superficie, gracias a la ley de Stefan-Boltzmann:

$$M_n = \sigma T^4 K \quad [2.7]$$

donde σ es la constante de Stefan-Boltzmann ($5.67 \times 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$), y T la temperatura en Kelvin. De esta fórmula resulta evidente que la emitancia global de un objeto es una función de su temperatura, y que pequeños cambios en ésta suponen notables modificaciones en la emitancia radiante. Por otra parte, conociendo la temperatura de un objeto emisor, podemos también estimar la irradiancia incidente sobre el sensor. La irradiancia radiante, es el total de energía radiada sobre una unidad de área y por unidad de tiempo. Es equivalente a la emitancia, si bien ésta indica la energía emitida, mientras la irradiancia refiere a la incidente (W / m^2).

Hasta aquí, hemos supuesto que las superficies naturales se comportan como cuerpos negros, lo cual es una exagerada simplificación. Por ello, se han de corregir las fórmulas anteriores añadiendo un nuevo parámetro, la emisividad, de acuerdo a la Ley de Kirchoff:

$$M = c M_n \quad [2.8]$$

La emisividad (c) es la relación entre la emitancia de una superficie (M), y la que ofrecería un emisor perfecto a la misma temperatura (M_n). Recordemos que a un emisor perfecto se le llama cuerpo negro, es decir un objeto que absorbe y emite toda la energía que recibe. También se habla de cuerpos blancos o reflectores perfectos, cuando no absorben nada de la energía incidente, sino que la reflejan por completo (emisividad = 0). Asimismo, se denominan cuerpos grises a aquellos objetos que absorben y emiten de forma constante en distintas longitudes de onda (emisividad constante). Cuando la emisividad varía con la longitud de onda, se habla de radiadores selectivos. Son los más frecuentes en la naturaleza. Gracias a ese comportamiento particular, pueden discriminarse de otro tipo de superficies en el infrarrojo térmico.

A partir de las fórmulas vistas en este apartado, podemos estimar la emitancia total y espectral de un objeto conociendo su temperatura absoluta, siendo aquella tanto mayor cuanto más alta sea ésta. En definitiva, la energía emitida desde un objeto es primariamente una función de su temperatura. Pequeños cambios en ésta suponen una modificación sensible de la emitancia total. Además, conociendo la temperatura de un objeto o cubierta de interés, y dado que puede estimarse su emisividad, puede determinarse la banda del espectro que resulte más idónea para su discriminación.

Con base en estas nociones, en la siguiente sección del capítulo, se abordará el comentario más detallado de la banda del espectro de interés en este trabajo: el dominio óptico del espectro. Se deja de lado en esta revisión el dominio de las microondas y el dominio del infrarrojo térmico, puesto que no se utilizarán estas longitudes de onda para el desarrollo del trabajo.

2.5 Dominio óptico del espectro

Se denomina dominio óptico del espectro a aquel grupo de longitudes de onda directamente dependientes de la energía solar. También se han incluido en esta parte las correspondientes al infrarrojo medio, puesto que mantienen una importante relación con esta fuente de energía, si bien se encuentran a medio camino entre ésta y la derivada de la emisión de calor que realizan los objetos.

Conviene analizar las características espectrales del sol, fuente primordial de energía radiante en nuestro planeta. El sol se encuentra a una temperatura radiante próxima a los 6000 K esto implica, según la ley de Wien que su máxima emitancia espectral se produce en torno a las $0.48 \mu\text{m}$, coincidente con la franja del espectro visible apreciado por nuestros ojos. La curva espectral de la radiación solar se asemeja bastante a la de un cuerpo negro a esa temperatura, tal y como se puede ver en la figura 2.5. En esta gráfica se observa cómo el sol presenta una banda de elevada emitancia entre 0.3 y $2 \mu\text{m}$, reduciéndose en valores más altos y más bajos de este sector por efecto de la atmósfera. A esa banda se le denomina dominio óptico del espectro, y constituye la región de mayor interés para la observación remota de la superficie terrestre.

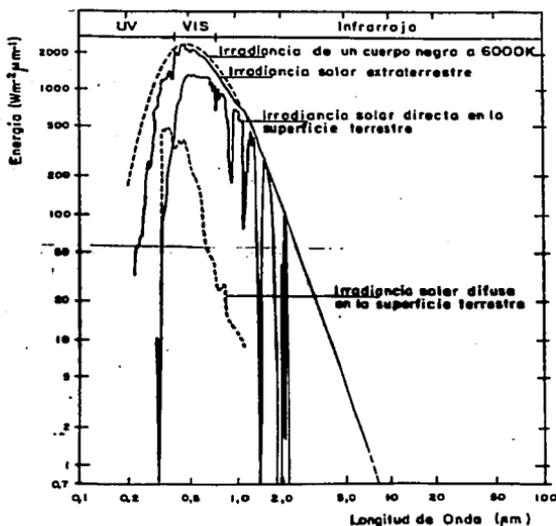


Fig. 2.5 Curva de emitancia radiativa del Sol.

Hasta aquí se ha considerado el origen de la radiación. Más importante es aún para nuestro objetivo es entender cómo este flujo interacciona con la superficie terrestre. Conocemos como flujo radiante (ϕ) al total de energía radiada en todas las direcciones por unidad de volumen, se mide en Jules por metro cúbico (J / m^3). La radiación que recibe la superficie terrestre puede descomponerse en tres términos (Fig. 2.6):

$$\phi_i = \phi_r + \phi_a + \phi_t \quad [2.9]$$

Esto significa que, el flujo incidente sobre una superficie es reflejado, transmitido o absorbido. Resulta conveniente expresar esta fórmula en unidades relativas. Para ello, basta dividir cada término de la expresión anterior por ϕ_i :

$$\frac{\phi_i}{\phi_i} = \frac{\phi_r}{\phi_i} + \frac{\phi_a}{\phi_i} + \frac{\phi_t}{\phi_i} \quad [2.10]$$

o, lo que es lo mismo:

$$1 = \rho + \alpha + \tau \quad [2.11]$$

siendo:

- ρ (reflectancia) la relación entre el flujo incidente y el reflejado por una superficie.
- α (absorbancia) la relación entre el flujo incidente y el que absorbe una superficie.
- τ (transmisividad) la relación entre el flujo incidente y el transmitido por una superficie.

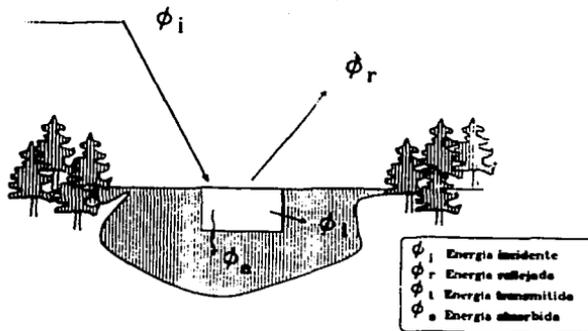


Fig. 2.6 Relación entre flujo incidente y reflejado.

La relación entre las tres magnitudes no es constante con la longitud de onda, por tanto, en términos más rigurosos, debería expresarse como:

$$I = \rho_{\lambda} + \alpha_{\lambda} + \tau_{\lambda} \quad [2.12]$$

La proporción del flujo incidente que es reflejado, absorbido y transmitido depende de las características de la superficie que se observa.

Debido a que esta proporción varía en distintas bandas del espectro, nos resulta muy interesante conocer el comportamiento de dicha cubierta en diversas longitudes de onda, de cara a realizar una más atinada discriminación, puesto que sólo cuando existan divergencias espectrales entre dos superficies podrán éstas separarse adecuadamente.

En el caso del espectro visible, ese comportamiento disimilar de los objetos a distintas longitudes de onda se manifiesta en lo que llamamos color: un objeto es azul si refleja intensamente la energía en esa banda del espectro y poco en el resto, mientras será verde si su reflectancia se centra en esa banda y es baja en otras.

A partir de medidas de laboratorio, se han obtenido unas curvas de reflectancia espectral para las principales cubiertas terrestres (Fig. 2.7). Como puede observarse, algunas tienden a presentar una respuesta uniforme en distintas longitudes de onda, mientras otras ofrecen un comportamiento mucho más selectivo. La nieve presenta una reflectancia alta y constante, pues refleja la mayor parte de la energía incidente a distintas longitudes de onda. Por el contrario, el agua absorbe la mayor parte de la energía que recibe, tanto más según nos situamos en longitudes de onda mayores. Por su parte, la vegetación presenta un comportamiento muy cromático, con bajos valores de reflectancia en el espectro visible y más elevados en el infrarrojo cercano.

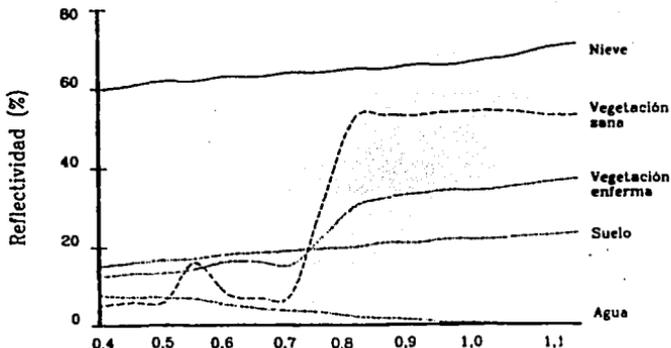


Fig. 2.7 Firmas espectrales típicas de distintas cubiertas.

Es importante considerar que el flujo de energía recibido por el sensor no sólo depende de la reflectancia de la cubierta, sino también de otros factores externos como los son la geometría de la observación, el emplazamiento ambiental de la cubierta y las condiciones atmosféricas.

En cuanto a las condiciones de observación, conviene tener presente que la cantidad de energía que llega al sensor depende del ángulo con que la superficie refleje la energía incidente, así como del que forme el haz incidente con la posición del sensor. Esta geometría de observación está estrechamente ligada a la rugosidad que presenta la superficie. Así, pueden distinguirse dos tipos de cubiertas:

- Aquellas que reflejan la energía con el mismo ángulo del flujo incidente (especulares).
- Aquellas que lo reflejan uniformemente en todas las direcciones (Lambertianas).

La mayor parte de las cubiertas tienden a comportarse de modo intermedio entre ambas situaciones, en función de sus características y de la longitud de onda en la que se trabaje. Si la longitud de onda es pequeña, las rugosidades del terreno tenderán a difundir mucho más la energía incidente que si se trata de longitudes de onda mayores, en donde esas mismas rugosidades no impiden un comportamiento especular. En el espectro visible, por ejemplo, sólo el agua en calma presenta un carácter casi especular, mientras el resto de las cubiertas tienden a ofrecer un comportamiento difusor.

En cualquier caso, el ángulo de elevación solar y el ángulo de observación juegan un papel muy destacado en la respuesta finalmente obtenida por el sensor. El sensor puede registrar un valor distinto de radiancia espectral para un mismo tipo de cubierta, con la misma o similar reflectancia, si varían las condiciones de observación o de iluminación. Además, la reflectancia presenta variaciones estacionales, muy notables en el caso de las cubiertas vegetales. En suma, el comportamiento de una cubierta en el espectro visible está influido no sólo por sus propias características, sino también por una serie de factores externos que modifican lo que podríamos llamar su comportamiento espectral teórico. Algunos de estos factores son (Chuvicco, 1990):

- i) Ángulo de iluminación solar, muy dependiente de la fecha del año y del momento de paso del satélite.
- ii) Modificaciones que el relieve introduce en el ángulo de iluminación (pendiente u orientación de las laderas).
- iii) Influencia de la atmósfera, especialmente en lo que se refiere a la dispersión selectiva en distintas longitudes de onda.
- iv) Variaciones medio ambientales en la cubierta: asociación con otras superficies, homogeneidad que presenta, estado fenológico, etc.
- v) Ángulo de observación, relacionado con la órbita del satélite y con las características del sensor.

El suponer que la interacción de la radiación electromagnética con las diversas cubiertas terrestres se realiza prácticamente como si se estuviera en el vacío, es falso. Entre el sensor y la superficie terrestre se interpone la atmósfera, que interfiere de formas diversas con el flujo radiante.

TESIS CON
FALLA DE ORIGEN

La atmósfera se compone de gases (dióxido de carbono, oxígeno, ozono, nitrógeno y argón, principalmente), vapor de agua y aerosoles. Entre estos componentes, el anhídrido carbónico, ozono y vapor de agua son los principales responsables de la interacción con la energía electromagnética. Su efecto es triple:

- i) Absorción de la energía en determinadas bandas del espectro, lo que limita la observación espacial a aquellas bandas en donde esta absorción es menos intensa o nula.
- ii) Dispersión, de determinados flujos, en función de su longitud de onda.
- iii) Emisión, como todo cuerpo caliente, que tiene su mayor importancia en el infrarrojo térmico.

En relación a la absorción atmosférica, podemos afirmar que la atmósfera se comporta como un filtro selectivo a distintas longitudes de onda, de tal forma que en algunas bandas del espectro elimina prácticamente cualquier posibilidad de observación remota. Los principales causantes de esta absorción son (Chuvieco, 1990):

- Oxígeno atómico (O_2), que filtra las radiaciones ultravioleta por debajo de $0.1 \mu m$, así como pequeños sectores en el infrarrojo térmico y las microondas.
- Ozono (O_3), responsable de la eliminación de la energía ultravioleta, inferior a $0.3 \mu m$, así como en un sector de las microondas (en torno a $27 mm$).
- Vapor de agua, con una fuerte absorción en torno a $6 \mu m$ y otras menores entre 0.6 y $2 \mu m$.
- Dióxido de carbono (CO_2), que absorbe en el infrarrojo térmico ($15 \mu m$), con importantes efectos en el infrarrojo medio, entre 2.5 y $4.5 \mu m$.

Como consecuencia de esta absorción, la observación espacial se reduce a determinadas bandas del espectro, conocidas como ventanas atmosféricas, en donde la transmisividad de la atmósfera es suficientemente alta (Fig. 2.8). Las principales ventanas atmosféricas son las siguientes:

- i) Espectro visible e infrarrojo cercano, situada entre 0.3 y $1.35 \mu m$.
- ii) Varias en el infrarrojo medio: de 1.5 a $1.8 \mu m$, 2.0 a $2.4 \mu m$, 2.9 a $4.2 \mu m$, y 4.5 a $5.5 \mu m$.
- iii) Infrarrojo térmico, entre 8 y $14 \mu m$.
- iv) Microondas, por encima de $20 mm$, en donde la atmósfera es prácticamente transparente.

Estas ventanas atmosféricas son idóneas para realizar la adquisición de datos a través de la Percepción Remota, por lo que el diseño de los sensores espaciales tiende a ajustarse a éstas bandas, evitando interferencias extrañas al fenómeno que pretende observarse. Por esto, no resulta muy habitual encontrar este problema en la interpretación de imágenes.

Mucho más complejo, sin embargo, es soslayar el efecto de dispersión causada por la atmósfera, presente, en mayor o menor grado, en cualquier imagen adquirida con sensores remotos.

TESIS CON
FALLA DE ORIGEN

La dispersión de la radiación electromagnética es causada por la interacción entre ésta y los gases y partículas atmosféricas en suspensión. La reflexión consiguiente a esta interacción supone un aporte adicional a la radiancia proveniente de la superficie terrestre (luz atmosférica). En definitiva, se reduce la radiancia directa, aumentándose la difusa. Puesto que las partículas atmosféricas son muy variables en el tiempo y en el espacio, resulta muy complejo cuantificar su influencia final en la imagen adquirida por el sensor. Sin embargo, se tendrá que tener en cuenta este factor, esencialmente cuando se pretenda convertir los valores digitales de la imagen a parámetros físicos (por ejemplo para establecer el contenido de humedad en la vegetación), o se aborden estudios multitemporales.

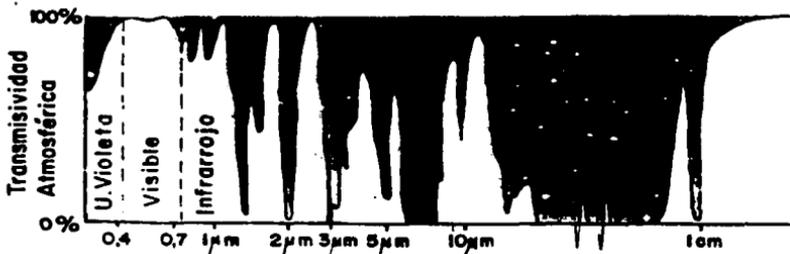


Fig. 2.8 Transmisividad de la atmósfera a distintas longitudes de onda.

El efecto de emisión atmosférica resulta fundamental en el trabajo dentro del infrarrojo térmico si se pretende obtener mediciones de temperatura a partir de las imágenes espaciales. Al igual que cualquier cuerpo por encima del cero absoluto, la propia atmósfera emite su propia energía calorífica, por lo que ese parámetro debe considerarse para estimar la emitancia espectral originalmente proveniente del suelo.

Todos los factores antes mencionados evidencian la complejidad que puede entrañar la caracterización de un tipo de cubierta a partir de sensores remotos. También sirven para matizar un tanto el concepto de firma espectral, ampliamente utilizado en estudios de Percepción Remota. Este concepto hace referencia al modo peculiar con el que una determinada cubierta refleja o emite energía a distintas longitudes de onda. Su forma característica de radiar energía sería la base para discriminar dicha cubierta, frente a otras, a partir de la observación remota. Ahora bien, este concepto debe matizarse, ya que, además del comportamiento espectral propio de cada cubierta, hay que considerar los factores arriba indicados, que modifican esa firma característica. En suma, las distintas cubiertas de la superficie terrestre no tienen un comportamiento espectral único y permanente, que coincida con sus curvas de reflectancia espectral y permita reconocerlas sin confusión frente a otras superficies. Por el contrario, en torno a un comportamiento tipo, que denominamos firma espectral, cada cubierta presenta una cierta variabilidad espectral, debida a los factores ya comentados, y que dificulta su discriminación de otras superficies.

Pese a estos comentarios, no cabe duda que las curvas de reflectancia son muy útiles para interpretar más fielmente la imagen, por cuanto relacionan los valores adquiridos por el sensor con las medias de laboratorio. A la vez, estas gráficas nos permiten seleccionar las bandas más convenientes para la detección de las cubiertas terrestres bajo estudio.

2.5.1 Características de la vegetación en el espectro óptico

La caracterización espectral de las masas vegetales ofrece notables dificultades como consecuencia de los múltiples factores que influyen en la radiancia final detectada por el sensor. En primera instancia, ha de considerarse la propia reflectancia de la hoja, en función de su estado, forma y contenido de humedad. Además es preciso tener en cuenta las características morfológicas de la planta: su altura, perfil, grado de cobertura del suelo, etc., que provocan una notable modificación en su comportamiento reflectivo. Un tercer grupo de factores serían los derivados de la situación geográfica de la planta: pendiente, orientación, asociación con otras especies, geometría de plantación, etc. A continuación se presentará el comportamiento espectral de la vegetación vigorosa.

El comportamiento espectral de la vegetación vigorosa muestra una reducida reflectancia en las bandas visibles, con un máximo relativo en la porción verde del espectro (en torno a $0.55 \mu\text{m}$). Por el contrario, en el infrarrojo cercano presenta una elevada reflectancia, reduciéndose paulatinamente hacia el infrarrojo medio (Fig. 2.9).

Estas características espectrales se relacionan, primordialmente, con la acción de los pigmentos foto-sintéticos y del agua que almacenan las hojas. En concreto, la baja reflectancia en la porción visible del espectro se debe al efecto absorbente de los pigmentos de la hoja, principalmente las clorofilas, xantofilas y carotenos (65, 29 y 6 %, respectivamente, aunque la proporción puede variar mucho). Todos ellos absorben en la banda del espectro situada en torno a los $0.445 \mu\text{m}$, mientras la clorofila presenta una segunda banda de absorción en torno a los $0.645 \mu\text{m}$. Entre ambas porciones del espectro, aparece una banda intermedia, alrededor de los $0.55 \mu\text{m}$, en donde el efecto absorbente es menor. Por esta causa aparece un pico relativo de reflectancia que coincide con la banda verde del espectro visible, y causa el color con el que nuestros ojos perciben la vegetación vigorosa.

Cuando se aproxima la caída otoñal de las hojas, la clorofila ejerce una menor influencia, lo que explica su mayor reflectancia en la banda roja y, en definitiva, su color amarillento (verde + rojo). En algunas especies resulta destacada la acción de otro pigmento, la antocianina, buen reflector de la porción roja del espectro, que causa ese color en épocas de senescencia.

En cuanto a la elevada reflectancia en el infrarrojo cercano, parece deberse a la estructura celular interna de la hoja. En concreto, la capa esponjosa del mesófilo, con sus cavidades de aire internas, ejerce un papel protagonista, al difundir y dispersar la mayor parte de la radiación incidente en esta banda del espectro. Por ello, la hoja sana ofrece una alta reflectancia en el infrarrojo cercano (entre 0.7 y $1.3 \mu\text{m}$), en claro contraste con la baja

reflectancia que ofrece en el espectro visible, especialmente con la banda roja. Puesto que la estructura de la hoja es muy variada según las especies, esta banda también resulta idónea para discriminar entre plantas, incluso entre aquellas que no podrían separarse en el espectro visible.

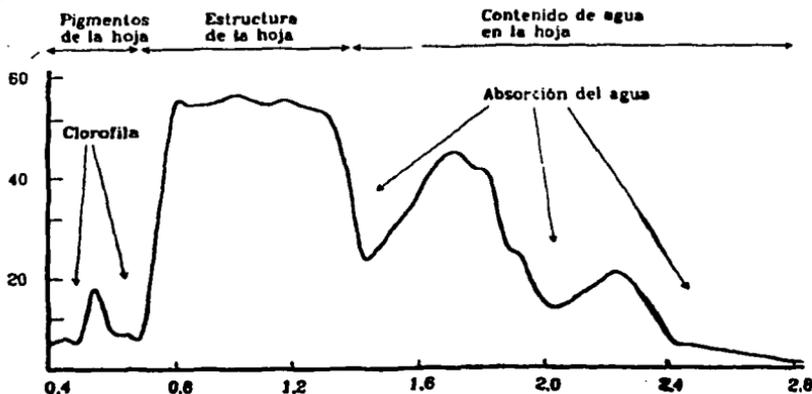


Fig. 2.9 Firma espectral de la vegetación sana

A partir de 1,4 μm el efecto absorbente del agua es muy claro, por lo que la reflectancia de la vegetación sana se reduce drásticamente en el infrarrojo medio. Las medidas de laboratorio muestran una notable diferencia en esta región del espectro entre las hojas secas y las infiltradas con agua. En experimentos con hojas de higuera, la reflectancia de la hoja seca alcanzó hasta cuatro veces el valor de la hoja húmeda, para la banda situada en torno a 1,9 μm . Entre estas bandas donde la absorción del agua es más clara, se sitúan dos picos relativos de reflectancia, en torno a 1,6 μm y 2,2 μm . Queda patente que la observación en esta región del espectro es de gran interés para conocer el estado de vigor de la hoja, en función de su contenido de humedad.

Obviamente el sensor no mide hojas aisladas, sino agrupaciones de hojas formando masas de vegetación, por lo que intervienen otros elementos adicionales que complican el esquema previo. Algunos de ellos son: el ángulo de elevación solar, directamente relacionado con la proporción de sombras que detecta el sensor; las características del suelo que sustenta la vegetación; la geometría de la cubierta vegetal; su estado fenológico, etc.

Pese a la complejidad final, es evidente que estas ideas nos sirven para centrar el estudio científico de la vegetación a partir de sensores espaciales. De ellas, resulta evidente que el contraste más nítido en la reflectancia espectral de la vegetación sana se produce entre

las bandas visibles, especialmente el rojo (en torno a $0.645 \mu m$), y el infrarrojo cercano (0.7 a $1.3 \mu m$). De ahí que podemos enunciar, como principio genérico, que cuanto mayor sea el contraste entre ambas bandas, mayor será el vigor de la vegetación, y más clara su discriminación frente a otros tipos de cubierta. Queda implícito que cualquier fuente de estrés en la vegetación se mostrará en un comportamiento espectral más o menos alejado del anteriormente expuesto. La hoja senescente o enferma tiende a perder actividad clorofílica y a ofrecer una menor absorbancia en las bandas azul y roja del espectro visible. El aumento consecuente de la reflectancia en estas bandas elimina el máximo relativo antes situado en el verde, por lo que la hoja tiende a mostrar un color amarillento. Por el contrario, en el infrarrojo cercano se produce una reducción de la reflectancia, como consecuencia de un deterioro en la estructura celular de la hoja. La curva espectral, por tanto, se hace más plana, menos cromática.

Este comportamiento espectral teórico de las cubiertas vegetales ha sido la base para obtener una serie de índices de vegetación, que se basan -entre otros factores- en el contraste entre las bandas roja e infrarroja cercana del espectro. Se construyen a partir de la combinación lineal entre estas dos bandas, cuando disponemos de una imagen multispectral. Muy variados en su desarrollo, todos ellos tienden a presentar de forma más nítida las características de la vegetación, facilitando su aislamiento de otras cubiertas y la detección de su estado vital. (Meliá et al. 1986; Meliá, 1986; Huete, 1987).

2.5.2 Características del suelo en el espectro óptico

Como consecuencia del efecto de pantalla provocado por la cubierta vegetal, no resulta sencillo obtener información del sustrato geológico a partir de sensores espaciales. Sin embargo, pueden obtenerse algunos datos indirectos sobre las características del suelo/litología gracias a las anomalías que puedan detectarse en esa cubierta vegetal. Ejemplos de este tipo de anomalías son: distribución peculiar de especies, crecimiento o densidad irregular, o alteraciones de la pigmentación o del ciclo fenológico. Esta técnica se ha bautizado con el nombre de Geobotánica.

En lo que atañe a los suelos desnudos, su comportamiento espectral es mucho más uniforme que el de la vegetación, mostrando una curva espectral bastante plana y de carácter ascendente. Los principales factores que intervienen en este caso son la composición química del suelo, su textura, estructura y contenido de humedad.

La composición química es la causa del color dominante con el que percibimos el suelo (Fig. 2.10). Los de origen calcáreo tienden al color blanco, indicando una alta reflectancia en todas las bandas visibles. En algunos casos, los suelos arcillosos ofrecen una mayor reflectancia en el rojo, como consecuencia de su alto contenido en óxido de hierro.

Respecto a las características físicas del suelo, puede afirmarse, en términos generales, que la reflectancia espectral resulta tanto mayor cuanto se trate de suelos más gruesos, apelmazados, secos y sin materia orgánica. El contenido de humedad es uno de los elementos

TESIS CON
FALLA DE ORIGEN

destacados importantes en la reflectancia de las longitudes de onda más largas, infrarrojo cercano y medio, como consecuencia de la alta absorbanza del agua en estas bandas. De hecho, un suelo de textura gruesa puede presentar una reflectancia menor que los finos cuando el contenido de humedad es bajo.

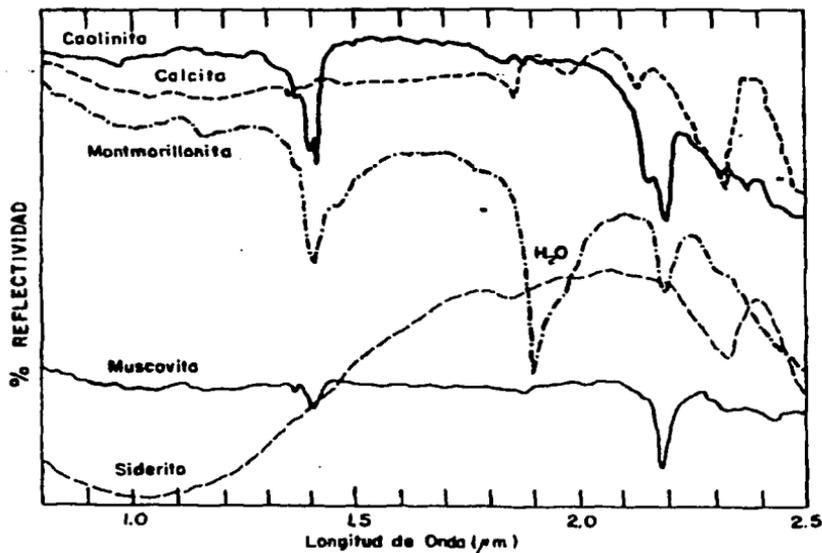


Fig. 2.10 Espectros de laboratorio para distintos minerales.

La textura, la estructura y el contenido de humedad están altamente relacionados. Por ejemplo, un suelo arcilloso tiende a tener un alto contenido de humedad, fuerte estructura y fina textura, lo que supone una baja reflectancia. En contraste, un suelo arenoso tiende a tener una estructura débil y un bajo contenido de humedad, por lo que presentará una reflectancia más elevada. A ello hay que añadir el efecto de la materia orgánica en el suelo que tiende a oscurecerle, y en consecuencia a reducir su reflectancia.

2.5.3 Características del agua en el espectro óptico

Las superficies acuáticas absorben o transmiten la mayor parte de la radiación visible que reciben, siendo mayor su absorbanza cuanto mayor sea la longitud de onda. La curva espectral, por tanto, es similar a la del suelo, aunque de sentido contrario. La mayor reflectancia del agua clara se produce en el azul, reduciéndose paulatinamente hacia el infrarrojo cercano, donde ya es prácticamente nula. Por esta razón, la frontera tierra – agua es muy nítida en esta banda.

La variabilidad del agua es más notable en las longitudes de onda más cortas (azul y verde). Esta variabilidad se relaciona con la profundidad, contenido de materiales en suspensión (clorofila, arcillas y nutrientes) y la rugosidad de la superficie.

La profundidad del agua influye directamente en el aporte de reflectancia derivado de los materiales de los fondos. En aguas poco profundas la reflectancia aumenta, por cuanto se produce un aporte de las características espectrales de los fondos. En consecuencia, la absorbanza será tanto mayor cuanto más profunda sea la capa de agua.

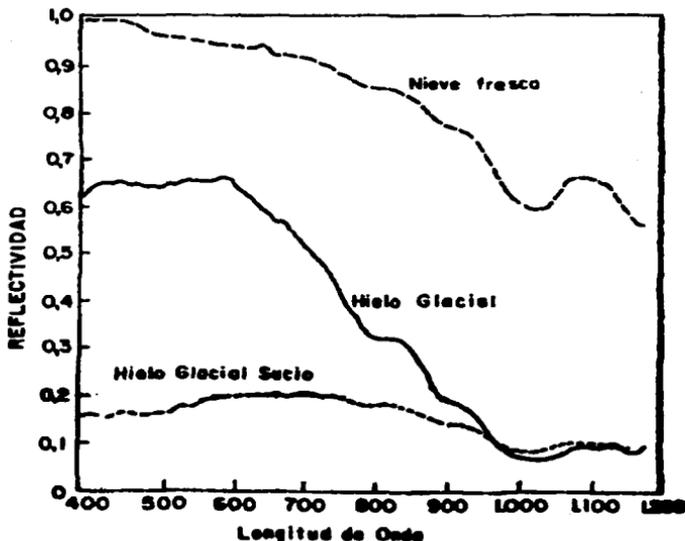


Fig. 2.11 Reflectancia característica para distintos tipos de nieve.

En cuanto a su composición, si el agua ofrece importantes concentraciones de clorofila, la reflectancia en el azul tiende a descender, aumentando en el verde. Esto permite establecer una clara correlación de signo negativo, entre la reflectancia del agua en la banda azul y el contenido de clorofila.

El resto de los materiales en suspensión contribuyen también a aumentar la reflectancia, además de presentar una mayor turbidez. Por último, la rugosidad de la superficie favorece la reflexión difusa, y en consecuencia una mayor reflectancia.

La nieve, por su parte, ofrece un comportamiento muy distante del agua. Presenta una reflectancia elevada en las bandas visibles, reduciéndose drásticamente hacia el infrarrojo cercano. También se presenta una disminución de esta reflectancia media, cuando aumenta el diámetro de los cristales. Otros factores destacados son el grado de compactación de la nieve y la impureza (Fig. 2.11). La reflectancia es mayor para la nieve fresca que para la helada, mostrando los valores más bajos la nieve sucia. La reducción puede llegar hasta el 80 % para las bandas visibles.

2.6 Fuentes de imágenes de Percepción Remota

La información adquirida por Percepción Remota de la superficie terrestre, ya sea de un avión, satélite u otra fuente, está ahora disponible siempre en formato digital. Espacialmente, los datos están compuestos por elementos discretos de una imagen y están cuantificados radiométricamente en niveles discretos de brillantez. Incluso si los datos obtenidos no están de forma original en formato digital, estos pueden ser transformados en datos discretos usando equipos de digitalización.

La gran ventaja de tener los datos en formato digital es que estos pueden ser procesados por computadora, ya sea para la extracción asistida de información o para mejorar la presentación final de los resultados.

En relación a la forma en que el sensor obtiene los datos, podemos clasificar estos en dos grupos:

- **Sensores pasivos:** se limitan a recoger la energía electro-magnética procedente de las cubiertas terrestres, ya sea ésta reflejada a partir de los rayos solares, o bien emitida en virtud de su propia temperatura. Dentro de estos podemos tener sensores fotográficos, óptico-electrónicos y de antena. En el primer grupo estarían las cámaras fotográficas. En el segundo, los exploradores de barrido y de empuje, y las cámaras vidicón. Por último, los sensores pasivos de antena se conocen con el nombre de radiómetros de micro-ondas.
- **Sensores activos:** la característica común de los sistemas activos es su capacidad de emitir un haz energético, que posteriormente recogen tras su reflexión sobre la superficie que se pretende observar. Entre ellos, el sistema más conocido es el radar, radiómetro activo de micro-ondas.

2.6.1 Resolución de un sistema sensor

Podemos definir la resolución de un sistema sensor como su habilidad para registrar, discriminándola, información de detalle. Esta definición engloba varios aspectos que merecen un comentario más detallado. Por un lado, se habla de resolución de un sistema sensor, indicando que este concepto se refiere al conjunto del equipo, y no a cada una de sus partes. Dicho de otra forma, la resolución de un sensor depende del efecto combinado de sus distintos componentes.

Los términos de la definición "discriminando" e "información de detalle" merecen también una breve reflexión. Ambos son relativos al propósito y al entorno geográfico del proyecto que se está abordando. La posibilidad de diferenciar varios objetos está en íntima relación con la escala de trabajo y con la complejidad del paisaje. Por ejemplo, pueden detectarse algunos rasgos geográficos, como ríos o carreteras, de anchura inferior a la resolución espacial del sensor, siempre y cuando exista suficiente contraste radiométrico entre la señal proveniente de estos rasgos y la de cubiertas vecinas. En otras palabras, cuanto mayor sea ese contraste entre cubiertas, más fácilmente se distinguirán éstas. En cuanto al significado de "información de detalle", conviene considerar que se refiere no sólo al detalle espacial que proporciona el sensor, sino también al número y anchura de las bandas del espectro que alberga, a su secuencia temporal, y a su capacidad para distinguir variaciones en la energía que detecta. En definitiva, el concepto de resolución implica, al menos, cuatro manifestaciones: espacial, espectral, radiométrica y temporal.

2.6.1.1 Resolución espacial

Este concepto designa al objeto más pequeño que puede ser distinguido sobre una imagen. En un sistema fotográfico, suele medirse como la mínima separación a la cual los objetos aparecen distintos y separados en la fotografía. Se mide en unidades de longitud (mm sobre la foto o m sobre el terreno), y depende de la longitud focal de la cámara y de su altura sobre la superficie.

Por su parte, en los sensores óptico-electrónicos, se prefiere utilizar el concepto de campo de visión instantáneo (*instantaneous field of view*, IFOV). El IFOV se define como la sección angular, medida en radianes, observada en un momento determinado. No obstante, se suele utilizar normalmente la distancia sobre el terreno que corresponde a ese ángulo, teniendo en cuenta la altura de vuelo y la velocidad de exploración del sensor. Simplificando las cosas, esa distancia se corresponde al tamaño de la mínima unidad de información incluida en la imagen, que se denomina píxel. Esta es la medida más generalizada de resolución espacial.

Conviene considerar que la resolución espacial de un sensor óptico-electrónico depende de varios factores, como son la altura orbital, velocidad de exploración, y número de detectores.

TESIS CON
FALLA DE ORIGEN

La resolución espacial de los sensores de observación terrestre en funcionamiento incluye un rango bastante amplio. Los satélites de recursos naturales, diseñados para adquirir información sobre áreas muy heterogéneas, suelen contar con resoluciones de cierto detalle: desde los 10 x 10 m del sensor SPOT-HRV, hasta los 120 x 120 m del canal térmico del Landsat-TM. Otro grupo de satélites orientado hacia aplicaciones más globales, como es el caso del HCMM-HCMR, MOS-VTIR, Nimbus-CZCS o NOAA-AVHRR, proporcionan píxeles de un tamaño comprendido entre 500 y 1.100 m de lado. En el último extremo del abanico estarían los satélites meteorológicos de órbita geoestacionaria (Meteosat, GOES, GMS), que ofrecen una cubierta global de la superficie terrestre, con píxeles de hasta 5 km.

La resolución espacial tiene un papel protagonista en la interpretación de la imagen, por cuanto marca, de alguna forma, el nivel de detalle que ésta ofrece. Con la salvedad antes referida, parece obvio decir que sólo son discriminables sobre la imagen elementos de tamaño superior, como mínimo, al del píxel, si bien diversos autores han demostrado que este umbral suele elevarse a cuatro veces ese tamaño mínimo (Jensen, 1986, p 113). En consecuencia, la resolución espacial está en estrecha relación con la escala de trabajo y con la fiabilidad finalmente obtenida en la interpretación. Cuanto menor sea el tamaño del píxel, menor también la probabilidad de que éste sea un compuesto de dos o más cubiertas fronterizas. Un píxel mixto está definido por una señal intermedia a las distintas cubiertas que lo componen. En consecuencia, puede no asemejarse a ninguna de ellas, lo que dificultará notablemente su identificación correcta. Sin embargo, en el caso concreto de algunas cubiertas, singularmente las urbanas, se ha comprobado que la resolución espacial puede afectar negativamente a la interpretación, cuando ésta se realiza digitalmente, esto debido a la gran heterogeneidad de cubiertas que la componen.

2.6.1.2 Resolución espectral

Indica el número y anchura de las bandas espectrales que puede discriminar el sensor. Como se vio anteriormente, es evidente el interés de contar con información multiespectral; esto es, de registrar simultáneamente el comportamiento de los objetos en distintas bandas del espectro. En este sentido, un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral de las distintas cubiertas. A la vez, conviene que esas bandas sean suficientemente estrechas, con objeto de recoger la señal sobre regiones coherentes del espectro. Bandas muy amplias suponen registrar un valor promedio, que puede encubrir la diferenciación espectral entre cubiertas de interés.

Entre los sensores espaciales, la menor resolución espectral corresponde al radar y a los sistemas fotográficos. El primero trabaja normalmente en un solo canal, mientras la fotografía puede ofrecer películas pancromáticas, infrarrojo b/n, color natural o infrarrojo color. Por el contrario los sensores ópticos-electrónicos ofrecen un amplio rango de bandas, si bien se presentan problemas de transmisión de datos para aumentar ese número.

La elección del número, anchura y localización de las bandas que incluye el sensor está estrechamente relacionada con los objetivos de su diseño. Para un sensor dedicado a fines meteorológicos, basta situar una sola banda en el visible, puesto que no existen diferencias

cromáticas en las nubes. Por el contrario, será conveniente que incluya una o dos bandas en el térmico (que le permitan conocer la temperatura de dichas nubes), y otra en el infrarrojo medio, en donde puede observarse el contenido de humedad en la atmósfera. Ésta es, precisamente, la distribución de bandas que recoge el sensor a bordo del satélite europeo Meteosat.

2.6.1.3 Resolución radiométrica

Se refiere a la sensibilidad del sensor, esto es, a su capacidad para detectar variaciones en la radiancia espectral que recibe. En el caso de los sistemas fotográficos, la resolución radiométrica del sensor se indica por el número de niveles de gris recogidos en el film. Para los óptico-electrónicos, la imagen habitualmente se presenta en formato digital, gracias a una conversión analógico-digital realizada a bordo del satélite. El número de valores que involucran ese rango -esto es, el número máximo de niveles digitales de la imagen-, suele identificarse con la resolución radiométrica del sensor. Este rango de codificación varía con los distintos sensores. Inicialmente los Landsat-MSS, ofrecían un rango de 128 niveles de codificación por píxel, 64 para el infrarrojo cercano. Actualmente, la mayor parte de los sistemas ofrecen 256 niveles por píxel (de 0 a 255), es decir 8 bits. La excepción es el NOAA-AVHRR, que trabaja con 1024 niveles, es decir 10 bits.

Al igual que en los otros tipos de resolución, cuanto mayor sea la precisión radiométrica, tanto mejor podrá interpretarse la imagen. El número de niveles más adecuado depende del método que se siga en la interpretación. Si ésta es visual, conviene considerar que el ojo humano difícilmente percibe más de 64 niveles de gris, y no más de 200 000 tonalidades. Algunos autores estiman que basta con 16 niveles por color (4 096 tonalidades) para garantizar un análisis visual adecuado, por lo que parece superfluo contar con 256 niveles digitales por banda (16 millones en una combinación coloreada de 3 bandas). Si se opta por la clasificación digital, la sensibilidad radiométrica puede ser mejor aprovechada, si bien algunos autores han demostrado que el aumento de 64 a 256 niveles no implica una mejora significativa en la clasificación de cubiertas vegetales.

2.6.1.4 Resolución temporal

Este concepto alude a la frecuencia de la cobertura que proporciona el sensor. En otras palabras, se refiere a la periodicidad con la que éste adquiere imágenes de la misma porción de la superficie terrestre. El ciclo de cobertura está en función de las características orbitales de la plataforma (altura, velocidad, inclinación), así como del diseño del sensor, principalmente del ángulo de observación y de abertura.

La cadencia temporal de los sistemas espaciales varía de acuerdo a los objetivos fijados para el sensor. Los satélites meteorológicos están obligados a proporcionar información muy

TESIS CON
FALLA DE ORIGEN

frecuentemente, ya que se dedican a observar fenómenos de gran dinamismo. De ahí que la red de satélites geoestacionarios (tipo Meteosat) proporcione una imagen cada 30 minutos, que complementa la obtenida a partir de los satélites de órbita polar, como el NOAA, que produce imágenes cada 12 horas. Por el contrario, los satélites de recursos naturales ofrecen una frecuencia mucho menor: entre los 16 días del Landsat y los 26 del SPOT.

Conviene aclarar que estos cuatro aspectos de la resolución están íntimamente relacionados. A mayor resolución espacial, disminuye habitualmente la temporal, y es previsible que se reduzca también la espectral y radiométrica. El principal problema se encuentra en la transmisión de imágenes a la superficie terrestre. El aumento en cualquiera de los cuatro tipos de resolución, significa también un incremento considerable del volumen de datos que, tanto el sensor como la estación receptora tienen que procesar y/o almacenar.

En consecuencia, al diseñar un sensor remoto habrá de enfatizarse el tipo de resolución más conveniente a sus fines. Si está orientado a la detección de fenómenos efímeros en el tiempo, deberá realizarse su cobertura temporal, aun a costa de perder resolución espacial, como ocurre con los satélites meteorológicos. Si, por el contrario, el sensor se orienta a exploración minera, el detalle espacial y espectral resulta más importante, reduciéndose entonces su ciclo temporal.

2.6.2 Satélites climáticos

Los satélites climáticos y los usados para recursos naturales operan, en gran parte, en las mismas bandas de longitud de onda. Quizás la mayor diferencia en las imágenes que estos entregan, estriba en la resolución espacial que tienen. Mientras que las imágenes obtenidas para propósitos de recursos naturales generalmente tienen una resolución espacial menor a 100 m en cada píxel, las usadas para aplicaciones meteorológicas usualmente están en el orden de 1 km por píxel. Esta es la característica principal usada para separar en dos tipos los satélites que obtienen datos de Percepción Remota. Sin embargo, debido a la similitud en longitud de onda y bandas que obtienen, sobre todo en algunos satélites climáticos como el NOAA (*Nacional Oceanic and Atmospheric Administration Satellite*) AVHRR (*Advanced Very High Resolution Radiometer*), las imágenes obtenidas pueden ser utilizadas para propósitos similares cuando se requiera una gran cobertura sobre un área determinada.

Dos grandes tipos de satélites climáticos son utilizados principalmente. Un tipo es el de órbita polar, o más comúnmente llamado de órbita baja terrestre. El otro tipo es el de órbita geoestacionaria. Los de órbita baja, orbitan generalmente a altitudes de entre 700 y 1500 km, mientras que los geoestacionarios orbitan a altitudes de aproximadamente 36 000 km. Ejemplos de los satélites de órbita baja son los actuales de la serie NOAA, así como sus predecesores TIROS, ITOS y TOS. Los satélites Nimbus son también de este tipo y orbitan alrededor de los 1000 km de altitud. Por otro lado, satélites meteorológicos geoestacionarios han sido lanzados por los Estados Unidos, la ex USRR, ESA (*European Space Agency*) y Japón, formando un sistema global de monitoreo atmosférico. Estos están localizados en órbitas ecuatoriales geo-sincronas a diferentes longitudes, para así cubrir la totalidad del globo

TESIS CON
FALLA DE ORIGEN

terrestre. A continuación se muestran las características generales de los principales satélites climáticos.

El AVHRR de NOAA ha sido diseñado para proporcionar información útil en estudios de hidrología, oceanografía y meteorología, aunque estos datos pueden ser también utilizados para el monitoreo de otros aspectos de la tierra. Si bien versiones anteriores del AVHRR contenían sensores para sólo cuatro bandas espectrales, versiones más recientes como las incluidas en el NOAA 12, tienen las siguientes características:

- Resolución espacial: 1.1 km.
- Resolución radiométrica: 10 bits.
- Cobertura terrestre: 2700 km.
- Bandas espectrales:
 - Banda 1 : 0.58 - 0.68 μm
 - Banda 2 : 0.72 - 1.1 μm
 - Banda 3 : 3.55 - 3.93 μm
 - Banda 4 : 10.3 - 11.3 μm
 - Banda 5 : 11.5 - 12.5 μm

El CZCS (*Costal Zone Colour Scanner*) que viene en el Nimbus 7 usa un sistema de barrido oscilatorio de espejo y está diseñado para medir las concentraciones de clorofila, distribución de sedimentos y la dinámica general de los océanos, incluyendo la temperatura de la superficie del mar. Este tiene las siguientes características:

- Resolución espacial: 825 m.
- Resolución radiométrica: 8 bits.
- Cobertura terrestre: 1566 km.
- Bandas espectrales:
 - Canal 1 : 0.433 - 0.453 μm
 - Canal 2 : 0.510 - 0.530 μm
 - Canal 3 : 0.540 - 0.560 μm
 - Canal 4 : 0.660 - 0.680 μm
 - Canal 5 : 0.700 - 0.800 μm
 - Canal 6 : 10.5 - 12.5 μm

Los satélites meteorológicos geostacionarios como el GMS (Japón) y el GOES (USA) tienen como principal sensor el VISSR (*Visible and Infrared Spin Scan Radiometer*), el cual obtiene información de la superficie terrestre mediante un sistema de barrido similar al del CZCS; sólo que en lugar de oscilar, aprovecha el eje del giro del satélite, el cual casi coincide con el eje norte-sur de la tierra; así adquiere una línea de imagen, y utiliza un motor de paso para ajustar el ángulo de vista en cada giro, y poder así obtener las sucesivas líneas de la imagen. El CZCS tiene las siguientes características:

- Bandas espectrales:
 - Visible : 0.433 - 0.453 μm

TESIS CON
FALLA DE CUBIEN

- Resolución espacial: 1.25 km.
- Resolución radiométrica: 6 bits.
- Infrarroja térmica : 10.5 - 12.5 μm
 - Resolución espacial: 5.0 km.
 - Resolución radiométrica: 8 bits.

Una versión mejorada del VISRR conocida como VAS (*VISRR and Atmospheric Sounder*) ha sido utilizada desde 1980 en la serie US GOES de satélites meteorológicos.

2.6.3 Satélites de recursos naturales

2.6.3.1 LANDSAT

El sistema Landsat de satélites de recursos naturales fue el primero en ser diseñado para obtener una cobertura de casi la totalidad de la superficie terrestre con bases regulares y predecibles. En consecuencia, ha sido el "caballo de trabajo" en la adquisición de imágenes de Percepción Remota, y se ha convertido en el punto de referencia con el cual se juzga a los nuevos sistemas.

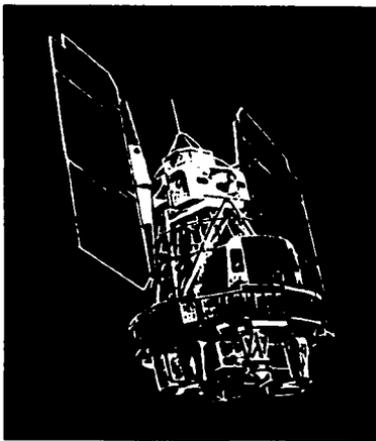


Fig. 2.12 Configuración de los satélites Landsat 1 a 3.

Los tres primeros satélites de la línea Landsat tenían características orbitales idénticas y tenían una forma muy similar a la del Nimbus, en forma de mariposa por la disposición de

los paneles solares (Fig. 2.12). Sus dimensiones eran de 3 m de altura por 1.5 m de diámetro, que se tornaban en 4 m cuando se extendían dichos paneles. El peso total del sistema se aproximaba a los 960 Kg. Su órbita era helio-síncrona, polar, ligeramente inclinada (99.1°), con una altura orbital media de 917 km, circundaba la tierra cada 103 minutos, con lo que realizaba 14 órbitas diarias para volver sobre la misma porción de la superficie terrestre a los 18 días, y a la misma hora local (entre las 9:30 y las 10:30 a.m. según latitudes). Con el fin de reducir al máximo las alteraciones en las condiciones de observación se dotó a los satélites de un sistema de estabilización según tres ejes, orientados hacia la superficie terrestre y la vertical del punto nadir. Las correcciones en la órbita, por tanto, se hacían desde las estaciones terrestres, lo que confería una gran estabilidad en la toma de datos.

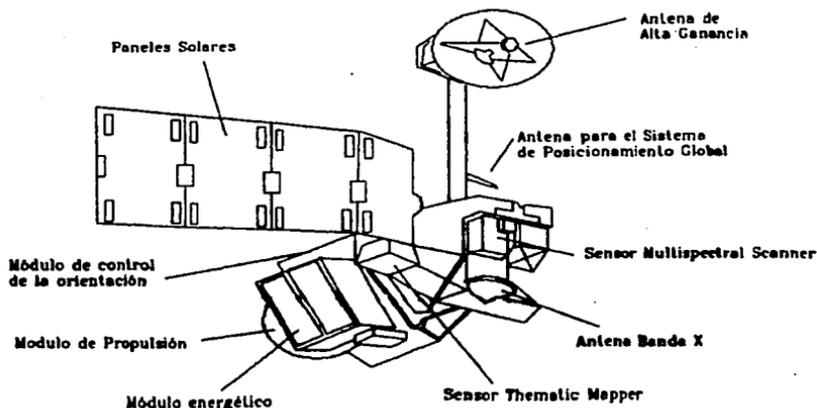


Fig. 2.13 Configuración de los Landsat 4y 5.

En el Landsat 4 y 5, se ve modificada su fisonomía (Fig. 2.13) y sus características orbitales. La altura de vuelo se reduce de 917 a 705 km, aunque se mejora el ciclo de recubrimiento, gracias a un menor periodo orbital (98.9 minutos), de 18 a 16 días y 14.56 órbitas por día dando un total de 233 revoluciones cada ciclo. El momento de adquisición, sin embargo, se mantiene en torno a las 9:45 a.m. aproximadamente. El Landsat 6, así como el Landsat 7 conservan los mismos parámetros orbitales, aunque para el Landsat 7 sus características cambian (Fig. 2.14).

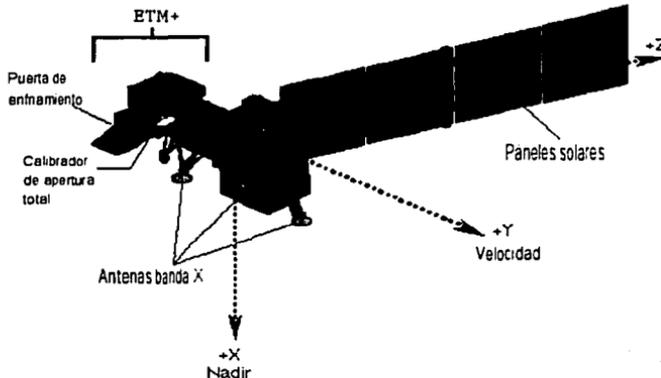


Fig. 2.14 Configuración del Landsat 7

Mientras que los Landsat 1, 2 y 3 tenían un sistema de grabación de cinta abordo, para poder guardar las imágenes cuando los satélites se encontraban fuera del área de cobertura de las estaciones terrestres, los Landsat 4 y 5 no tenían ningún sistema de grabación y dependían únicamente de la transmisión directa a las estaciones terrestres o de la transmisión vía los satélites de comunicación geosíncronos TDRS (*Tracking and Data Relay Satellite*). TDRS es un satélite de comunicaciones de alta capacidad que es usado para respaldar datos de un gran número de misiones, incluyendo el *Space Shuttle*. Su estación receptora en tierra se encuentra en *White Sands*, Nuevo México, donde la información es reenviada vía satélites de comunicación domésticos. En el caso del Landsat 6, este contaba también con un sistema de grabación además de la transmisión directa. En este momento es importante mencionar que el Landsat 6 falló casi desde el momento mismo de su lanzamiento el 10 de mayo de 1993. En el Landsat 7 se incluye un sistema de grabación de estado sólido (SSR, *Solid State Recorder*), con una capacidad de 378 Gigabits.

Los 3 primeros Landsat incorporaban un equipo de barrido multiespectral denominado MSS (*Multispectral Scanner*) y un conjunto de tres cámaras vición (RBV, *Return Beam Vidicon*). Los Landsat 4 y 5 eliminan las cámaras y las sustituyen por un nuevo explorador de barrido, denominado TM (*Thematic Mapper*) que proporciona mayor resolución espacial y espectral que el previo MSS. Sin embargo, para asegurar la continuidad en la serie de datos, se mantiene en estos satélites el MSS, con características similares a los anteriores. El Landsat 6 contenía sólo una versión ampliada del TM llamada ETM (*Enhanced Thematic Mapper*), la cual difiere de la anterior en que se le agrega una banda pancromática con una resolución espacial de 15 m. Por último, el Landsat 7 incluye el ETM+ (*Enhanced Thematic Mapper Plus*), el cual es muy parecido al ETM perdido con el Landsat 6, difiriendo de este, entre otras

cosas, por una mejora en la resolución espacial de la banda térmica (de 120 m a 60 m) y la adición de dos calibradores solares. En la tabla 2.1 se muestran las principales características de cada misión Landsat.

Tabla 2.1 Características de la misión Landsat.

Sistema	Lanzamiento (Fuera de servicio)	I(s)	Resolución (metros)	Comunicaciones	Alt. Km	R Días	D Mbps
Landsat 1	7/23/72 (1/6/78)	RBV MSS	80 80	Enlace directo con grabadoras	917	18	15
Landsat 2	1/22/75 (2/25/82)	RBV MSS	80 80	Enlace directo con grabadoras	917	18	15
Landsat 3	3/5/78 (3/31/83)	RBV MSS	30 80	Enlace directo con grabadoras	917	18	15
Landsat 4	7/16/82	MSS TM	80 30	Enlace directo TDRSS	705	16	85
Landsat 5	3/1/84	MSS TM	80 30	Enlace directo TDRSS	705	16	85
Landsat 6	10/5/93 (10/5/93)	ETM	15 (pan) 30 (ms)	Enlace directo con grabadoras	705	16	85
Landsat 7	4/99	ETM+	15 (pan) 30 (ms)	Enlace directo con grabadoras (de estado sólido)	705	16	150

I(s) = Instrumento(s)

R = Ciclo de repetición

D = Ancho de banda

La transmisión TM falló en Agosto de 1993

Actualmente transmite solo por enlace directo y no permite la grabación

El sensor MSS es un equipo de barrido óptico electrónico. Su campo de visión es de 11.56°, lo que, a la altura orbital del satélite, le permite explorar una franja de terreno de 185 km. divididos a ambos lados de la vertical de la traza.

Con objeto de acoplar la secuencia de barrido a la velocidad del satélite, el sensor MSS registra seis líneas simultáneamente con cada oscilación del espejo. La radiancia recibida por el sistema focal se transmite a un sistema óptico que la descompone en cuatro bandas, y la envía a distintos detectores. Por tanto, el MSS dispone de 24 detectores (6 líneas x 24 bandas), compuestos por fotodiodos de silicio (banda 7), y por tubos fotomultiplicadores (bandas 4 a 6). En el caso del Landsat 3, se añadió una banda térmica (banda 8), registrada por detectores de mercurio-cadmio-telurio. La cobertura espectral ofrecida por el MSS aparece en la tabla 2.2.

Una escena adquirida por el sensor MSS comprende 2 340 líneas de barrido y 3 240 columnas por línea. Cada pixel correspondió a una superficie real de 79 m de lado (0.62 Ha), si bien en la transformación digital se le asigna un formato nominal de 57 x 79 m, lo que explica la asimetría final entre el número de líneas y de columnas en la imagen. La radiancia recibida

para esa parcela del terreno se transforma a un valor entero, para su almacenamiento. Ese valor, en los primeros MSS, estaba comprendido entre 0 y 127 para las bandas 4 a 6, y entre 0 y 63 para la banda 7. Los siguientes MSS codifican las cuatro bandas entre 0 y 255, la medida estándar en un equipo de tratamiento digital.

En el diseño del sensor MSS se tuvieron en cuenta las medidas espectrales de laboratorio, de tal forma que las 4 bandas finalmente incluidas pretenden realzar la aplicación de este sensor a la detección de masas vegetales, recursos hídricos y mineros. Las bandas visibles (4 y 5), tienen mejores disposiciones para la detección de áreas urbanas o vías de comunicación, a la vez que proporcionan una interesante información sobre la calidad del agua. Las dos bandas en el infrarrojo cercano (6 y 7) pretenden registrar parámetros vitales en la actividad de las plantas, además de ser especialmente sensibles a la humedad.

Los dos primeros satélites Landsat incorporaron un sistema de tres cámaras RBV, cada una de las cuales registraba información en una banda espectral comprendida entre el verde y el infrarrojo cercano (tabla 2.2). Su resolución espacial se cifraba en 80 m, cubriendo la misma porción superficial del sensor MSS.

Este sistema no funcionó adecuadamente en los dos primeros Landsat, por lo que fue sustituido en el tercero por otro sistema vidicón. En este caso, el planteamiento se dirigió más a mejorar la resolución espacial que la espectral, por lo que se montaron dos cámaras pancromáticas de alta resolución operando simultáneamente con el MSS. Estas cámaras cubrían un abanico espectral de 0.505 a 0.705 μm , proporcionando -en cuatro adquisiciones- la misma cobertura del MSS, pero con una resolución aproximada de 40 m. El registro entre ambas permitió utilizar el RBV como auxiliar del MSS, especialmente para mejorar la calidad visual de sus imágenes.

En el campo de las aplicaciones temáticas, el RBV se ha utilizado en estudios morfológicos y en cartografía de la cubierta del suelo, si bien la escasa pervivencia de este sensor ha reducido sensiblemente su rango de aplicaciones.

El *Thematic Mapper* (TM) está directamente diseñado, como su nombre lo indica, para la cartografía temática. Al igual que su predecesor, el MSS, el TM es un equipo de barrido multispectral, que emplea una técnica muy similar a la descrita previamente. Sin embargo, las novedades que incorpora permiten considerarlo como perteneciente a una nueva generación de sensores. Frente al MSS, el TM aumenta el número de detectores, de 24 a 100, a la vez que se reduce el IFOV, se aumentan los niveles de codificación, y se realiza el barrido en las dos direcciones. Todo ello le permite mejorar la resolución espacial, espectral y radiométrica: de 79 a 30 m, de 4 a 7 bandas, y de 6 a 8 bits. En el TM cada oscilación del espejo supone 16 líneas de barrido, frente a 6 en el MSS. De esta forma se precisan 16 detectores por banda, salvo la banda térmica que registra una menor resolución (120 m) y sólo requiere cuatro detectores. Este aumento en el número de detectores complica el proceso de calibración, a la par que aumenta el volumen de datos a procesar. Los detectores están formados por tubos de silicio, para las bandas 1 a 4, indio-antimonio para las bandas 5 y 7, y mercurio-cadmio-telurio para la banda 6.

comercializar cortes de escena, bandas aisladas e incluso sub-imágenes de 512 x 512 píxeles, a la vez, que ganan un creciente interés las técnicas numéricas de compactación, como son el análisis de componentes principales.

En relación al ETM y al ETM+, ya se ha mencionado anteriormente que su funcionamiento es muy similar al TM, y de la misma forma ya se han mencionado sus diferencias y mejoras.

2.6.3.2 SPOT

Uno de los proyectos más novedosos, frente al estándar marcado por el programa Landsat, ha sido el proyecto SPOT (*Système Probatoire d'Observation de la Terre*), desarrollado por el CNE francés, en colaboración con Bélgica y Suecia. El primer satélite SPOT se lanzó en 1986, mientras el segundo se ha puesto en órbita a inicios de 1990.

Entre las novedades más interesantes de este satélite, se cuenta la incorporación de dos equipos de exploración por empuje denominados HRV (*Haute Resolution Visible*). En esta tecnología de exploración "por empuje" (*pushbroom*), se elimina el espejo oscilante, gracias a disponer de una cadena de detectores que cubre todo el campo de visión del sensor. Estos detectores se van excitando con el movimiento orbital del satélite, de ahí el nombre de explorador de empuje, puesto que se explora, en cada momento, una línea completa, desplazándose ésta simultáneamente con la plataforma. Los detectores sólidos que forman un explorador por empuje se denominan dispositivos de acoplamiento por carga (*Charge Couple Devices, CCD*). Estos dos sensores permiten obtener imágenes en dos modalidades: pancromático y multi-banda (verde, rojo e infrarrojo cercano), con una resolución espacial de 10 y 20 m, respectivamente (tabla 2.3). El área cubierta en cada escena es de 60 km de lado, por lo que estos sensores necesitan incorporar 3000 detectores en modo multispectral y 6000 en modo pancromático. La resolución radiométrica por píxel es de 8 bits en multi-banda y 6 en pancromático.

Otra importante novedad del satélite SPOT es su capacidad para variar el ángulo de observación, gracias a un dispositivo móvil instalado en el equipo óptico. Esto le permite observar la misma zona en órbitas sucesivas, reduciendo la frecuencia temporal de las imágenes (de 26 días a 2-3 días según las latitudes). Esa misma capacidad, permite al SPOT adquirir imágenes estereoscópicas, lo que añade a su potencial temático una clara capacidad topográfica. En definitiva, la flexibilidad del sistema le facilita adaptar su órbita a las necesidades del usuario.

La mejora en resolución espacial frente al sensor TM hace a las imágenes SPOT idóneas para tareas de análisis visual especialmente en el medio urbano. Asimismo se han desarrollado técnicas para combinar el canal pancromático de SPOT con imágenes TM, de tal forma que se aproveche la resolución espectral de este último, recogiendo de alguna forma la resolución espacial del primero.

TESIS CON
FALLA DE ORIGEN

Tabla 2.3 Características del satélite SPOT y el sensor HRV

SPOT:	Altitud	832 km
	Órbita	Helio-síncrona, 98.7° de inclinación, atraviesa el ecuador a las 10:30 a.m.
	Ciclo de repetición	26 días
HRV	Modo multispectral	Modo Pancromático
bandas	0.50-0.59 μm	0.51-0.73 μm
	0.61-0.68 μm	
	0.79-0.89 μm	
IFOV	20 m x 20 m	10 m x 10 m
Rango dinámico	8 bit	8 bit
Ancho por escena	60 km	60 km

2.6.3.3 Skylab

El Skylab fue puesto en órbita en Mayo de 1973 y sacado de servicio en Febrero de 1975. Cargaba con un gran número de paquetes de instrumentos, uno de los cuales fue conocido como EREP (*Earth Resources Experiment Package*). Tenía una órbita inclinada a 50° del ecuador, a una altitud de 435 km. Desde esta órbita era capaz de observar hasta un 75% de la superficie terrestre.

El EREP tenía seis tipos de sensores, uno de los cuales era un equipo de barrido óptico electrónico multispectral. Como el MSS del Landsat, este sensor obtenía imágenes de la superficie terrestre, en bandas espectrales con un formato discreto. Las bandas espectrales que abarcaba el EREP del Skylab se presentan en la tabla 2.4.

Tabla 2.4 Características de las imágenes del Skylab S 192 MSS

Canal 1. 0.41-0.46 μm	Canal 8. 0.98-1.08 μm
2. 0.46-0.51 μm	9. 1.09-0.19 μm
3. 0.52-0.56 μm	10. 1.20-1.30 μm
4. 0.56-0.61 μm	11. 1.55-1.75 μm
5. 0.62-0.67 μm	12. 2.10-2.35 μm
6. 0.68-0.76 μm	13. 10.2-12.5 μm
7. 0.78-0.88 μm	
	Resolución espacial = 79 m
	Ancho de escena = 72.4 km
	Rango dinámico = 8 bit

TESIS CON
FALLA DE ORIGEN

2.6.3.4 MOS

El satélite japonés MOS (*Marine Observation Satellite*) compuesto por los satélites MOS-1 y MOS-1b, que fueron lanzados en febrero de 1987 y en enero de 1990 respectivamente, y se diseñaron inicialmente para la investigación oceánica. Su carga útil se compone de los siguientes sensores: un equipo de exploración por empuje, bautizado como MESSR (*Multispectral Electronic Self- Scanning Radiometer*), con una resolución de 50 m y cuatro bandas espectrales, dos en el visible y dos en el infrarrojo cercano; un explorador de barrido, denominado VTIR (*Visible and Thermal Infrared Radiometer*), con una banda en el visible y tres en el infrarrojo térmico (resolución espacial de 900 y 2 700 m, respectivamente); y un radiómetro de microondas, el MSR (*Microwave Scanning Radiometer*), operando a 23 y 31 GHz, con resolución de 32 y 23 km, respectivamente. Las características de sus sensores son mostradas en la tabla 2.5.

Tabla 2.5 Características de órbita y de los sensores del MOS.

MOS:	Altitud	909 km
	Órbita	Heliosíncrona, 99.1° de inclinación, cruzando el ecuador a las 10-11 am
	Ciclo de repetición	17 días
MESSR:	Bandas	0.51-0.59 μm 0.61-0.69 μm 0.73-0.80 μm 0.80-1.10 μm
	IFOV	50 m x 50 m
	Rango dinámico	8 bit
	Ancho de escena	100 km
VTIR:	Bandas	0.5-0.7 μm 6.0-7.0 μm 10.5-11.5 μm 11.5-12.5 μm
	IFOV	900 m x 900 m para el canal visible 2700 m x 2700 m para los otros
	Rango dinámico	8 bit
	Ancho de escena	1500 km

3. PROCESAMIENTO DIGITAL DE LA IMAGEN

3.1 Formatos de datos de una imagen digital

En el caso de los equipos óptico-electrónicos, el sensor explora secuencialmente la superficie terrestre, adquiriendo -a intervalos regulares- la radiación que proviene de los objetos situados sobre ella. La frecuencia con la que el sensor realiza ese muestreo de la superficie terrestre define precisamente la resolución espacial del mismo. Dicho en otras palabras, el sensor detecta la radiancia media de una parcela del terreno equivalente al tamaño del píxel, unidad visual más pequeña que aparece en la imagen. Este valor medio se traduce por el sensor a un valor numérico, a partir del cual se realiza el tratamiento digital de imágenes. En consecuencia, cada píxel de la imagen viene definido por un número entero, traducción de la radiancia recibida por el sensor para una determinada parcela de la superficie terrestre y en una determinada banda del espectro. Este valor numérico se denomina nivel digital (ND), valor del píxel o nivel de gris. En resumen, la unidad mínima de información en una imagen digital se denomina píxel, definido por un número entero, ND, que puede convertirse en una intensidad luminosa o nivel de gris.

Teniendo presentes estas ideas, la organización de los datos en una imagen multispectral digital puede esquematizarse en la figura 3.1. Como se ve, se trata de una matriz numérica de tres dimensiones. Las dos primeras corresponden a las coordenadas geográficas de la imagen, mientras la tercera indica su dimensión espectral. La orientación aproximada Norte-Sur se expresa a través de las filas de la matriz, que normalmente reciben el nombre de líneas (*line*), mientras las columnas (*column*) indican la disposición Oeste-Este. En esta matriz, el origen de coordenadas se sitúa en la esquina superior-izquierda (línea 1 columna 1), en lugar del borde inferior-izquierdo, como ocurre en cualquier eje cartesiano. Esto es debido a la secuencia de adquisición de imágenes, de Norte a Sur, de acuerdo a la traza del satélite. La tercera dimensión corresponde a la resolución espectral del sensor. En consecuencia, habrá tantos planos en la imagen como bandas originalmente detectadas: por ejemplo 7 para el TM.

La imagen digital esta grabada normalmente en código binario, utilizando 8 bits para almacenar el ND de cada píxel. Estas a su vez contienen normalmente un archivo de cabecera (*header file*) en donde se almacena el formato con el que están grabados los ND que la componen, así como las condiciones en que se adquirió la imagen (tipo de sensor, localización de la escena, día, elevación y azimut solar, etc.), y el tipo de correcciones aplicadas por la estación receptora. Por ejemplo las imágenes ETM, vienen con un archivo extra de información que incluye todos estos datos.

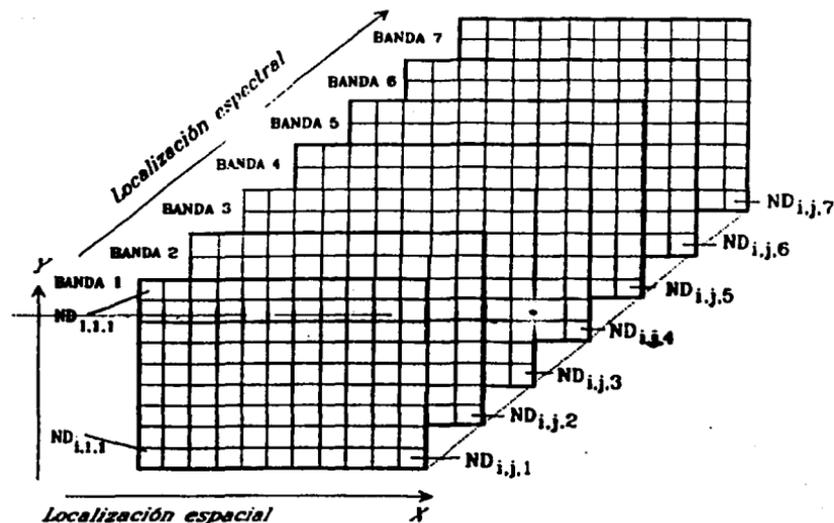


Fig. 3.1 Organización de una imagen multispectral digital.

Para guardar la imagen multispectral en archivos, existen diferentes formatos, de los cuales los tres más habituales son:

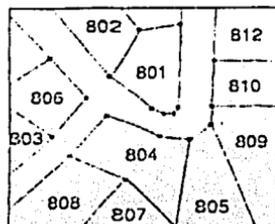
- Bandas secuenciales (*Band Sequential*, BSQ). Implica que los ND de cada banda se disponen uno a continuación del otro hasta completar todos los píxeles de una banda. En el caso de las CCT se situaban los ND de cada banda uno tras otro hasta completar todas las bandas espectrales. En la actualidad los píxeles de cada banda componen un archivo separado. Es bastante habitual en la distribución de las imágenes Landsat.
- Bandas intercaladas por línea (*Band Interleaved by Line*, BIL). En este caso, los ND se organizan por líneas en lugar de por bandas, disponiéndose consecutivamente los correspondientes a todas las bandas, para cada línea, antes de comenzar la línea siguiente. En definitiva, tras los ND de la línea 1, banda 1, se sitúan los correspondientes a la línea 1, banda 2, para luego continuar los de la banda 3, 4, etc., hasta completar el número total de bandas. Tras la primera línea de la última banda se sitúa la segunda línea de la banda 1, de la banda 2, y así sucesivamente. Es común en las imágenes SPOT-HRV, aunque también se utiliza con imágenes Landsat-TM o de otros sensores.

- **Píxeles intercalados** (*Band Interleaved by Pixel*, BIP). En lugar de alternarse los ND en cada línea, se alternan en cada píxel. Así, tras el ND correspondiente al píxel de la línea 1, columna 1, banda 1, aparece el correspondiente a la línea 1, columna 1, banda 2, seguido del adquirido para la línea 1, columna 1, banda 3, etc. Este formato es práctico si todas las bandas van a ser usadas.

Para poder realizar un procesamiento digital a una imagen, obviamente esta imagen debe de estar en formato digital. No todas las fuentes de datos espaciales nos entregan imágenes o datos en formato digital. Sin embargo, siempre se puede transformar estos datos a un formato digital, incluso cuando los datos que se tengan estén en forma de un mapa analógico, pues estos se pueden digitalizar antes de ser introducidos a una base de datos.

En general, para representar datos espaciales, se usan dos tipos de formatos: *raster* y *vector*. El formato *raster* incluye la representación que previamente se ha señalado tienen las imágenes obtenidas de los dispositivos ópticos-electrónicos. Es decir se tiene un conjunto de píxeles en un arreglo de malla rectangular, en el cual cada píxel tiene un valor numérico entero que puede representar ya sea un código de atributo cualitativo o un valor de atributo cuantitativo. Como ejemplo de representación de atributos cualitativos, tenemos el mapa de uso de suelo de una zona, en el cual se asigna un cierto valor de un código a cada píxel que corresponda a los diferentes tipos de suelo que se tengan reconocidos. En el caso de la representación de atributos cuantitativos, ésta se puede ejemplificar con las imágenes obtenidas de un dispositivo óptico-electrónico como las que se mencionaron anteriormente, debido a que cada píxel nos representa un valor de alguna variable a estudiar. En las imágenes que se han visto, el valor entero de cada píxel representa la radiancia recibida por el sensor.

En el formato *vector* las fronteras o el curso de los objetos esta definido por una serie de puntos que, cuando se unen con una línea continua, forman la representación gráfica del objeto. Los puntos que conforman la línea son codificados cada uno con un par de números que nos dan las coordenadas a las cuales esta referenciado el objeto (Fig. 3.2). Los atributos de cada objeto pueden ser guardados usando bases de datos. Este formato puede ser muy útil en los GIS (Sistemas de Información Geográfica), puesto que los atributos de cada objeto pueden ser fácilmente referenciados con una base de datos. De igual manera, hay sistemas que manejan las imágenes en formato *vector*, sobre todo en la impresión de éstas, puesto que este formato mejora y supera las limitaciones de impresión de las imágenes *raster*. Por último, conceptualmente y algunas veces en la práctica, se tiene que pasar primero por el formato *vector* para luego llegar al *raster* cuando se quiere digitalizar un mapa que esta en formato analógico. Este es el caso de mapas en papel, con los cuales se utilizan digitalizadores en forma de pluma o cursor, con los cuales se van marcando la serie de puntos que componen el mapa. De esta forma se obtiene primero un formato *vector* que luego puede ser convertido en formato *raster*.



ID	LAND-USE	AREA
801	201	6305
802	202	6412
803	112	7221
804	201	12532
805	312	14638
806	201	6120
807	111	8914

Vector



0	0	0	0	0	1	1	1	1
0	0	0	0	0	1	1	1	1
0	0	0	0	0	1	1	1	1
0	0	0	0	0	1	1	1	1
1	0	0	1	0	1	1	1	1
1	1	1	1	1	0	0	0	0
1	1	1	1	1	0	0	0	0
1	1	1	0	0	0	0	0	0
1	1	1	0	0	0	0	0	0

Raster

Fig. 3.2 Formato vector y raster,

3.2 Consideraciones de un sistema de procesamiento digital de imágenes multiespectrales

Un sistema de procesamiento digital de imágenes consiste en el hardware de la computadora y el software de procesamiento de imágenes necesario para el análisis digital de los datos de una imagen digital.

A continuación se presentarán las generalidades que componen tanto el hardware como el software, puesto que particularizar en un área que cambia continuamente sería dar información que rápidamente pueden convertirse en obsoleta.

TESIS CON
FALLA DE ORIGEN

3.2.1 Hardware

Podremos dividir en dos el tipo de hardware requerido para el procesamiento digital de una imagen: estaciones de trabajo y computadoras personales (PC). Si bien una estación de trabajo contará siempre con un mayor poder computacional, el hecho de que sea mucho más costosa que una PC, y que en la actualidad el desarrollo de las PC sea muy rápido, hace que para la gran mayoría de las aplicaciones de procesamiento digital de una imagen, baste con una PC con lo último en avances con que se cuenten, para poder desarrollar satisfactoriamente nuestro análisis.

El primer factor a considerarse es el CPU (*Central Processing Unit*), el cual es la base de funcionamiento de la máquina: recibe los datos de las unidades de entrada, los almacena provisionalmente en la memoria central, los procesa de acuerdo a las instrucciones que recibe del usuario a través de un programa, y envía los resultados a una unidad externa. Dentro de este aspecto hay que mencionar que la velocidad de los procesadores que podemos encontrar varía comercialmente de forma muy rápida, mejorando así la velocidad con la cual se ejecuta el análisis de la imagen. Es en esta característica es donde radica la principal diferencia entre las PC y las estaciones de trabajo, ya que estas últimas manejan una arquitectura RISC (*Reduced Instruction Set Computer*) la cual permite realizar más rápidamente las instrucciones, si bien al parecer la velocidad del procesador sea más lenta que el de una PC con la misma velocidad.

Aparte de la velocidad del procesador, otro factor que mejora dramáticamente la velocidad con la cual nuestra computadora realice el procesamiento de la imagen, es la cantidad de memoria RAM. En este aspecto, debido a que cada vez ésta se hace más barata, conviene más invertir en grandes cantidades de memoria RAM que en tener lo último en velocidad de los procesadores.

En lo concerniente a la capacidad de almacenamiento permanente, conviene destacar que hay que tratar de que ésta sea lo más grande posible, es decir debemos tener presente que necesitaremos un disco duro de gran capacidad, puesto que la mayoría de las veces trabajaremos con imágenes bastante grandes.

En relación a las unidades de entrada-salida, en la actualidad se hace imprescindible contar con una unidad de CD grabable, debido a que otro tipo de unidad, como lo es la de disquetes, no es para nada útil si se tiene en cuenta que prácticamente ninguna imagen que obtengamos es menor a la capacidad que estos tienen. Además el CD se ha convertido en una de las formas más comunes para recibir y enviar datos de este tipo. Otra forma que ha ganado gran importancia para adquirir imágenes de satélites, es vía Internet, debido a que la gran mayoría de las empresas que distribuyen estas imágenes, cuentan con el servicio de distribución vía FTP (*File Transfer Protocol*). Obviamente debemos contar con una conexión rápida, pues si no esta vía de obtención de imágenes se hace inoperante.

Para el despliegue de las imágenes en el monitor, este debe de tener la mejor resolución posible, así como tratar de que contemos con el mayor tamaño de monitor que podamos. Esto debido a que, entre más "espacio de trabajo" tengamos, será más fácil trabajar con la imagen o

incluso con varias imágenes al mismo tiempo. Aquí cabe resaltar que para que valga la pena contar con un buen monitor, debemos considerar también en invertir en una buena tarjeta de video, puesto que si esta no es lo suficientemente buena, aunque el resto de nuestro equipo sea de lo mejor, el despliegue de las imágenes será muy lento.

En lo relativo a la impresión de las imágenes en papel, el hecho de que actualmente se cuente con equipos con calidad fotográfica, ayuda mucho. Si bien la mayoría de las veces bastará con una impresora de inyección de tinta para imprimir las imágenes, si se necesita mucha exactitud en la impresión de mapas, se puede considerar el uso de una *plotter*, teniendo en cuenta que estos equipos tienen la desventaja de que son muy costosos.

3.2.2 Software

En relación al software tenemos dos aspectos a considerar: sistema operativo y programas de aplicación. El uso de un sistema operativo dependerá en gran medida del hardware que estemos ocupando. Si contamos con una estación de trabajo seguramente se manejará algún sistema operativo basado en UNIX. Por otro lado, si con lo que contamos es una PC, seguramente estaremos trabajando con algún sistema operativo de la generación DOS-WINDOWS. Si bien, en el caso de una PC podemos trabajar con LINUX (sistema operativo del tipo UNIX), debemos tener en cuenta que la disponibilidad de aplicaciones y controladores para nuestro hardware es mayor para DOS-WINDOWS, aunque en la actualidad el desarrollo de LINUX ha ido igualando estas circunstancias. También existe la posibilidad de utilizar un sistema operativo propio para Macintosh, si se cuenta con una PC de este tipo, la cual es muy buena para el trabajo de imágenes, pues su arquitectura se acerca más a la de una estación de trabajo. La desventaja de usar esta plataforma radica en la menor disponibilidad de aplicaciones propias para el procesamiento digital de imágenes.

Los programas de aplicación pueden ser realizados directamente por el usuario. Para esto se necesita contar con el compilador propio para el lenguaje de programación que vayamos a utilizar, como lo es C, C++, Fortran, etc. Si bien esta opción es muy útil cuando se necesite utilizar algoritmos que no se encuentran comercialmente, no es muy común recurrir a ésta cuando se pretende ocupar algoritmos más comunes. En este caso es mejor recurrir a software comercial o público especializado en el procesamiento digital de imágenes. Esto es debido a que este software puede estar ya bastante optimizado, además de incluir múltiples utilidades extras que facilitan la obtención de resultados. Por ejemplo, es común encontrar software especializado que permita integrar distintos algoritmos o métodos en el procesamiento de una imagen. Esto es útil incluso cuando se quiere probar algún algoritmo nuevo, pues la gran mayoría de este software incluye herramientas para poder implementar nuestros propios algoritmos de manera sencilla. En la tabla 3.1 se incluye una referencia de software utilizado para el procesamiento digital de imágenes en aplicaciones de mapas de recursos terrestres.

TESIS CON
FALLA DE ORIGEN

Tabla 3.1 Sistemas de procesamiento digital de imágenes comerciales usados para hacer mapas de recursos terrestres y sus capacidades (círculo blanco = capacidades moderadas; círculo completo = capacidad significativa; sin círculo = capacidad reducida o nula)

Sistemas	Sistema Operativo	Preprocesado	Despliegue y realce	Extracción de información	Linaje	Cartografía imagen/mapa	GIS	IP/GIS
Comercial								
Adobe Photoshop	Dos/Mac/ UNIX	○	●					
CAD Overlay GS	Dos	○	○					
CORE HardCore	Dos/UNIX	○	○	○				
CORE ImageNet	Dos/UNIX	○	○	○				
Decision Images	Dos	●	●	●		●	●	●
EarthView	Dos	●	●	●				
EIDETIC	Dos	○	○	○				
ESRI Arc-Info GRID	UNIX	○	○	○		●	●	●
Dragon	Dos	●	●	●				
ERDAS Imagine	Dos/UNIX	●	●	●	●	●	●	●
ER-Mapper	UNIX	●	●	●		●	●	●
GAIA	Macintosh	○	○	○				
GENASYS	Dos/UNIX	●	●	●		●	●	●
Gentis	Dos	○	○	○				
Global Lab Image	Dos		●	○				
GRASS	UNIX	●	●	●	●	●	●	●
IDRISI	DOS	●	●	●		●	●	●
Intergraph	UNIX	●	●	●	●	●	●	●
PCI	Dos/UNIX	●	●	●		●	●	●
R-WEL	Dos	●	●	●		●	●	●
MacSadie	Macintosh	●	●	●				
MicroImages	Dos/UNIX	●	●	●	●	●	●	●
MOCHA landel	Dos/Win- dows	●	●	●				
OrthoView	UNIX	●	●					
SPANS GIS/MAP	Dos/Mac	○	○	○		●	○	○
VISILOG	Dos/UNIX	●	●	●				

3.3 Cálculo de estadísticas de la imagen

Es muy útil el calcular las estadísticas fundamentales *univariable* y *multivariable* de los datos de una imagen multiespectral. Dentro de estos está incluido el cálculo de valores mínimos y

máximos para cada banda de las imágenes multispectrales, el rango, media, desviación estándar, matriz de varianza-covarianza entre bandas, matriz de correlación, y la frecuencia de nivel de gris (ND), los cuales son usados para generar histogramas. Estos valores estadísticos nos proporcionan información valiosa y necesaria, como se verá más adelante, para el despliegue y análisis de datos obtenidos de percepción remota.

El procesamiento digital de imágenes es usualmente realizado con sólo una muestra de la información de percepción remota. Por eso, es muy útil hacer una revisión de algunos aspectos elementales de la teoría estadística. Una *población* es un conjunto infinito o finito de elementos. Una población infinita serían todas las imágenes que pudieron ser adquiridas de la tierra en un año determinado. Una población finita serían las imágenes Landsat obtenidas en un año de una zona determinada. Una *muestra* es un subconjunto de elementos tomados a partir de una población, usada para hacer inferencias acerca de ciertas características de la población. Un ejemplo de muestra sería el obtener una imagen de Landsat en un tiempo y una zona determinados.

Si algunas observaciones con ciertas características son sistemáticamente excluidas de una muestra, ya sea voluntaria o involuntariamente (como lo sería obtener imágenes solamente de la primavera), la muestra será *sesgada*. El *error de muestreo* es la diferencia entre el valor de una característica en la población y el valor de esa misma característica inferido a partir de una muestra.

Las muestras grandes obtenidas aleatoriamente a partir de poblaciones naturales usualmente generan distribuciones de frecuencia simétricas, como la mostrada en la figura 3.3a. Muchos valores están agrupados alrededor de algún valor central y la frecuencia de ocurrencia declina fuera de este valor central. La gráfica de distribución tiene la forma de una campana y es llamada *distribución normal*. Muchas pruebas estadísticas usadas en el análisis de datos de percepción remota asumen que los ND tienen una distribución normal. Desafortunadamente estos datos no siempre tienen una distribución normal y el análisis debe realizarse tomando en cuenta estas consideraciones.

3.3.1 Histograma de la imagen

El histograma es una representación gráfica de la información contenida en una imagen de percepción remota, que es muy útil en el procesamiento de los datos. Los histogramas de cada una de las bandas del conjunto de imágenes multispectrales son usualmente desplegados en muchos estudios, porque nos dan una representación de la calidad de los datos originales; por ejemplo la calidad de su contraste, ya sea alto o bajo. De hecho, muchos analistas rutinariamente incluyen histogramas de los conjuntos de imágenes, ya sea de la imagen original como de la imagen modificada, para documentar los efectos de la aplicación de técnicas de realce de imágenes. A continuación se hará una revisión de cómo se construye el histograma de una imagen de una banda k , compuesta por i líneas y j columnas con valores de nivel de gris ND para cada píxel.

Histogramas de distribuciones simétricas y sesgadas

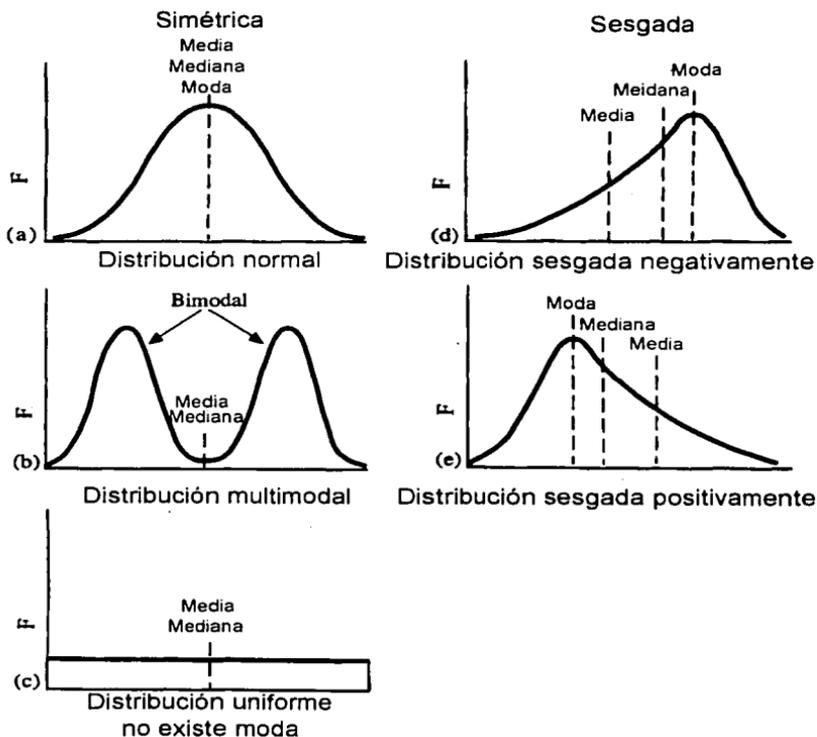


Fig. 3.3 Posición relativa de las medidas de tendencia central para las distribuciones de frecuencia más comunes.

Las bandas individuales de datos de percepción remota son típicamente cuantificadas (guardadas digitalmente) con ND que van del rango de 2^8 a 2^{12} . Si definimos como $cuant_k$ al nivel de cuantificación de la banda k , entonces si $cuant_k = 2^8$ es el rango de ND podría ser de 0 a 255, o si $cuant_k = 2^{12}$ el rango de ND podría ser de 0 a 4095. La mayoría de los datos actuales están cuantificados con 8 bits, con valores en un rango de 0 a 255, por ejemplo las

imágenes de Landsat TM y SPOT HRV. Si tabulamos la frecuencia de ocurrencia de cada ND dentro de la imagen, obtenemos información estadística que puede ser desplegada gráficamente en una *histograma*. El rango de valores de cuantificación de la banda, cuant., está representado en la abscisa (eje x), mientras que la frecuencia de ocurrencia de cada uno de estos valores está desplegada en la ordenada (eje y). Por ejemplo, considerando el histograma de una escena Charleston, S.C. obtenida de la banda 4 del Landsat TM (Fig. 3.4), podemos observar que los picos en el histograma corresponden a los tipos dominantes de cubierta terrestre en la imagen: (a) agua, (b) tierras húmedas y (c) tierras altas. También, cabe destacar que se nota como los datos están comprimidos en menos de una cuarta parte del rango de 0 a 255, con lo cual podemos inferir que la imagen tiene un contraste bajo. Esta es una información muy importante cuando se realiza un realce del contraste.

El histograma es una ayuda gráfica importante para entender el contenido de los datos de percepción remota. Información cuantitativa adicional acerca de los datos de percepción remota, puede ser obtenida calculando estadísticas *univariable y multivariable*.

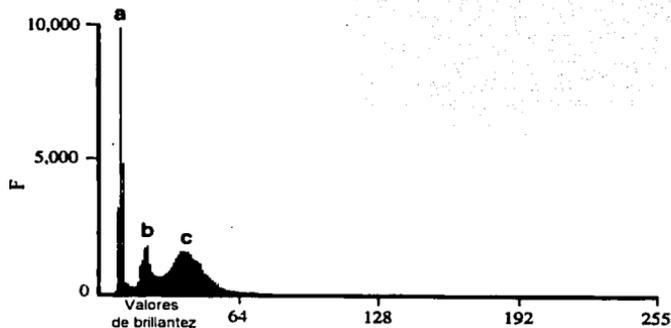


Fig. 3.4 Histograma multimodal.

3.3.2 Estadísticas *univariable* de la imagen

El analista de una imagen tiene a su disposición las medidas estadísticas de tendencia central. La *moda* (marcada en la figura 3.3a) es el valor que mas frecuentemente ocurre en una distribución y es usualmente el punto más alto en la curva. Es común, sin embargo, encontrar más de una moda en un conjunto de datos, como en el ejemplo mostrado en la figura 3.3b, así como en el de la figura 3.4., pero en este último caso, así como tiene múltiples modas, también tiene una distribución no simétrica (sesgada).

La *mediana* es el valor medio en la distribución de la frecuencia (marcada en la figura 3.3a), esto es, una mitad del área bajo la curva de distribución se encuentra a la derecha de la mediana, y la otra mitad a la izquierda de esta.

La *media* (μ) es el promedio aritmético y está definido como la suma de todas las observaciones dividida entre el número de observaciones. Esta es la medida de tendencia central más comúnmente usada. La media de una sola banda, μ_k , compuesta por n niveles de gris es calculada usando la fórmula:

$$\mu_k = \frac{\sum_{i=1}^n ND_{ik}}{n} \quad [3.1]$$

Donde ND_{ik} representa el i -ésimo ND en la banda k .

La media de una muestra, es una estimación no sesgada de la media de la población y, para distribuciones simétricas, tiende a estar tan cerca de la media de la población tanto como cualquier otra estimación no sesgada, tal como lo son la mediana y la moda. La media es una medida de tendencia central pobre cuando el conjunto de observaciones esta sesgado o contiene valores extremos. Cuando el pico (moda) comienza a ubicarse cada vez más a la derecha o izquierda de la media, se dice que la distribución de frecuencia esta *sesgada*. Si el pico (moda) se encuentra a la derecha de la media, la distribución de frecuencia está sesgada negativamente, por otro lado si el pico se encuentra a la izquierda de la media, la distribución de frecuencia está sesgada positivamente (Fig. 3.3d y e).

Las medidas de dispersión con respecto a la media de una distribución son también importantes. Por ejemplo, el *rango* de una banda (rango_k) es calculado a partir de la diferencia entre el más alto y el más bajo valor observado, también llamados máximos (max_k) y mínimos (min_k) valores, respectivamente. Entonces, $\text{rango}_k = \text{max}_k - \text{min}_k$. Desafortunadamente, cuando los valores máximos y mínimos son observaciones extremas o inusuales, el rango es una medida de dispersión engañosa. Cuando no existen valores inusuales, el rango es una importante estadística comúnmente usadas en funciones de realce de imágenes, como es el caso de la compresión del contraste por mínimo-máximo.

La *varianza* de una muestra es el promedio de la desviación de todas las observaciones posibles con respecto a la media de la muestra, elevada ésta desviación al cuadrado. La varianza de una banda, var_k se calcula usando la siguiente ecuación

$$\text{var}_k = \frac{\sum_{i=1}^n (ND_{ik} - \mu_k)^2}{n} \quad [3.2]$$

El numerador de la expresión, $\sum_{i=1}^n (ND_{ik} - \mu_k)^2$ es la *suma de cuadrados corregida* (SS). Si la media de la muestra (μ_k) fuera realmente la media de la población, ésta podría ser una

medida muy exacta de la varianza. Desafortunadamente, hay cierto error en el cálculo usando la ecuación 3.2, debido a que la media de la muestra (calculada con la ecuación 3.1) fue obtenida de manera que se minimizaran las desviaciones al cuadrado a partir de ésta. Es por esto, que el denominador de la ecuación de la varianza se reduce a $n - 1$, produciendo una estimación no sesgada de la varianza de la muestra.

$$\text{var}_k = \frac{SS}{n-1} \quad [3.3]$$

La *desviación estándar* es la raíz cuadrada positiva de la varianza. La desviación estándar de los píxeles en una banda, s_k , se calcula:

$$s_k = \sqrt{\text{var}_k} \quad [3.4]$$

Una desviación estándar pequeña sugiere que las observaciones están agrupadas muy cerca del valor central. De forma inversa, una desviación estándar grande indica que los valores están muy esparcidos con respecto a la media.

El área total por debajo de la curva en una distribución normal, es igual a 1.00 (o 100%). Para una distribución normal, 68.27% de las observaciones se encuentran entre los valores de ± 1 , con respecto a la media, de desviación estándar, 95% cae entre los valores ± 2 de la desviación estándar, y el 99% entre ± 3 de la desviación estándar. La desviación estándar es una estadística comúnmente utilizada para realizar el procesamiento digital de imágenes, por ejemplo en el realce lineal del contraste, en la clasificación por paralelepípedo, y en la evaluación de errores.

3.3.3 Estadísticas multivariable de la imagen

Debido a que, en imágenes obtenidas por percepción remota, la mayoría de las veces trabajaremos con más de una banda espectral, es muy útil el cálculo de medidas estadísticas multivariable, como lo son la covarianza y correlación entre las bandas para determinar como estas medidas varían una con respecto a la otra. Más adelante se verá como la varianza-covarianza y las matrices de correlación son usadas en el análisis de componentes principales (PCA) y en la clasificación, entre otras aplicaciones. Por esta razón, a lo largo de esta sección se verá como la varianza-covarianza entre bandas es calculada y procesada para obtener la correlación entre bandas. Aunque este ejemplo se realizará con un conjunto simple de sólo 5 píxeles, se mostrará la utilidad de estas medidas estadísticas.

A continuación nos basaremos en considerar los cinco primeros píxeles [(1,1), (1,2), (1,4) y (1,5)] de 4 bandas multiespectrales (MSS - verde, roja, infrarroja cercana, infrarroja cercana) obtenidas de una zona con vegetación (Tabla 3.2). Hay que notar que los bajos valores de ND en la banda 2 están provocados por la absorción de la luz roja de la clorofila de las plantas por parte de los procesos fotosintéticos. El incremento en la reflectancia de la energía infrarroja incidente por parte de las plantas, nos da como consecuencia altos valores en

TESIS CON
FALLA DE ORIGEN

las dos bandas del infrarrojo cercano (bandas 3 y 4). Aunque es una muestra pequeña de datos, ésta representa muy bien las principales características de una zona de vegetación verde saludable.

Tabla 3.2 Conjunto de datos de ejemplo de valores de brillantez usados para demostrar la obtención de la matriz de varianza-covarianza.

Píxel	Banda 1 (verde)	Banda 2 (rojo)	Banda 3 (infrarrojo cercano)	Banda 4 (infrarrojo cercano)
(1,1)	130	57	180	205
(1,2)	165	35	215	255
(1,3)	100	25	135	195
(1,4)	135	50	200	220
(1,5)	145	65	205	235

Las estadísticas *univariable* simples para este tipo de datos, se presentan usualmente como se muestra en la tabla 3.3. En este ejemplo, la banda 2 muestra la varianza (264.8) y desviación estándar (16.27) mas pequeñas, el valor de ND más bajo (25), el rango más pequeño de ND ($65 - 25 = 40$), y el valor de media más pequeño (46.4). En contraparte, la banda 3 tiene la varianza (1007.5) y desviación estándar (31.74) más grandes y el rango de ND más grande ($215 - 135 = 80$). Estas estadísticas *univariable* son de valor, pero no proveen información útil acerca de si los valores espectrales de las cuatro bandas varían juntos o son completamente independientes entre sí.

Tabla 3.3 Estadísticas univariable para el conjunto de datos de ejemplo.

Banda	1	2	3	4
Media	135.00	46.40	187.00	222.00
Desviación estándar	23.71	16.27	31.74	23.87
Varianza	562.50	264.80	1007.50	570.00
Mínimo	100.00	25.00	135.00	195.00
Máximo	165.00	65.00	215.00	255.00
Rango	65.00	40.00	80.00	60.00

Los diferentes valores espectrales para cada píxel a veces varían juntos en ciertos patrones predecibles. Si no existe relación entre los valores de ND de una banda con otra para un cierto píxel, se dice que estos valores son mutuamente independientes, es decir, un incremento o decremento en los valores de ND de una banda no está acompañado por un cambio predecible en los valores de ND de otra banda. Debido a que los valores espectrales de un píxel podrían no ser independientes, es necesaria alguna medida de su interacción mutua. Esta medida, llamada *covarianza*, es la variación conjunta de dos variables en relación a su media común. Para calcular la covarianza, primero se necesita calcular la *suma de productos corregida* (SP) definida por la siguiente ecuación:

$$SP_{kl} = \sum_{i=1}^n (ND_{ik} - \mu_k)(ND_{il} - \mu_l) \quad [3.5]$$

En la anterior fórmula tenemos que los subíndices de SP, representan dos bandas espectrales l y k , por lo tanto es la SP entre dos bandas l y k . ND_{ik} es la i -ésima medida de ND de la banda k , y ND_{il} es la i -ésima medida de ND de la banda l , ambas con n píxeles en el área de estudio. Las medias de las bandas k y l son μ_k y μ_l respectivamente. En el ejemplo, la variable k podría representar la banda 1 y la variable l la banda 2. Computacionalmente es más eficiente usar la siguiente fórmula, la cual nos da el mismo resultado:

$$SP_{kl} = \sum_{i=1}^n (ND_{ik} \times ND_{il}) - \frac{\sum_{i=1}^n ND_{ik} \sum_{i=1}^n ND_{il}}{n} \quad [3.6]$$

La cantidad es llamada suma de productos no corregida. La relación entre SP_{kl} con la suma de cuadrados (SS) se puede observar si hacemos que k y l sean el mismo, esto es:

$$SP_{kk} = \sum_{i=1}^n (ND_{ik} \times ND_{ik}) - \frac{\sum_{i=1}^n ND_{ik} \sum_{i=1}^n ND_{ik}}{n} = SS_k \quad [3.7]$$

Así como la varianza simple fue calculada dividiendo la suma de cuadrados corregida (SS) entre $(n - 1)$, la covarianza es calculada dividiendo SP entre $(n - 1)$. Entonces, la covarianza entre los ND en las bandas k y l , cov_{kl} , es igual a:

$$cov_{kl} = \frac{SP_{kl}}{n - 1} \quad [3.8]$$

Las sumas de productos (SP) y las sumas de cuadrados (SS) pueden ser calculadas para todas las combinaciones posibles de las cuatro bandas espectrales de la tabla 3.2. Estos datos pueden ser presentados en un arreglo de una matriz de varianza-covarianza de 4×4 , tal como se muestra en la tabla 3.4. Todos los elementos en la matriz que no se encuentren en la diagonal, estarán duplicados (por ejemplo, $cov_{1,2} = cov_{2,1}$, por lo que $cov_{kl} = cov_{lk}$).

Tabla 3.4 Formato de la matriz de varianza-covarianza.

	Banda 1	Banda 2	Banda 3	Banda 4
Banda 1	SS ₁	Cov _{1,2}	cov _{1,3}	cov _{1,4}
Banda 2	cov _{2,1}	SS ₂	cov _{2,3}	cov _{2,4}
Banda 3	Cov _{3,1}	Cov _{3,2}	SS ₃	Cov _{3,4}
Banda 4	Cov _{4,1}	Cov _{4,2}	Cov _{4,3}	SS ₄

TESIS CON
FALLA DE ORIGEN

El cálculo de la varianza, para los elementos en la diagonal, y de la covarianza, para los elementos que no se encuentran en la diagonal, se muestra en la tabla 3.5.

Tabla 3.5 Matriz de varianza-covarianza para los datos del ejemplo.

	Banda 1	Banda 2	Banda 3	Banda 4
Banda 1	562.50			
Banda 2	135.00	264.80		
Banda 3	718.75	275.25	1007.50	
Banda 4	537.50	64.00	663.75	570.00

Para estimar el grado de interrelación entre las variables, de modo que no se vean influenciadas por las unidades de medida, se usa el *coeficiente de correlación r*. La correlación entre dos bandas, r_{kl} , es el cociente de su covarianza (cov_{kl}) con el producto de sus desviaciones estándar ($s_k s_l$), entonces:

$$r_{kl} = \frac{cov_{kl}}{s_k s_l} \quad [3.9]$$

Debido a que el coeficiente de correlación es un cociente, éste es adimensional. Como la covarianza puede ser igual, pero nunca mayor que el producto de las desviaciones estándar de sus variables, estará entre el rango de +1 a -1. Un coeficiente de correlación de +1, indica una positiva y perfecta relación entre los ND de dos bandas, es decir, si los ND de una banda se incrementan, los ND de la otra banda se incrementarán de forma perfectamente sistemática. Por otro lado, un coeficiente de correlación de -1, indica que las dos bandas están inversamente relacionadas, es decir, si los ND de una banda se incrementan, los ND de la otra banda decrecerán sistemáticamente. Las correlaciones entre los valores +1 y -1 se van haciendo cada vez menos perfectas, conforme estas se alejan de los extremos. Por lo tanto, un coeficiente de cero indica que no existe relación lineal entre las dos bandas de datos de los sensores remotos.

Las correlaciones entre bandas son presentadas comúnmente en una matriz de correlación como la mostrada en la tabla 3.6, la cual contiene las correlaciones entre las bandas del ejemplo que se ha trabajado. Generalmente, sólo los coeficientes por debajo de la diagonal son mostrados, debido a que los coeficientes en la diagonal tienen valor de 1.0 y los que se encuentra por encima de ésta están duplicados.

Tabla 3.6 Matriz de correlación para los datos del ejemplo.

	Banda 1	Banda 2	Banda 3	Banda 4
Banda 1	---			
Banda 2	0.35	---		
Banda 3	0.95	0.53	---	
Banda 4	0.94	0.16	0.87	---

TESIS CON
FALLA DE ORIGEN

En el ejemplo que se ha venido mostrando, los ND de la banda 1 están altamente correlacionados con los de las bandas 3 y 4, esto es $r \geq 0.94$. Una alta correlación nos sugiere que existen cantidades considerables de información redundante entre estas bandas. Quizás una o más de estas bandas podrían dejarse fuera del análisis, para reducir el subsiguiente cálculo computacional.

3.4 Despliegue de imágenes multispectrales

Los humanos estamos muy acostumbrados al procesamiento visual de imágenes con tonos continuos, como lo hacemos diariamente al leer revistas, periódicos o al ver televisión. Aprovechando esta característica propia del ser humano, se tiene como objetivo el presentar la información obtenida por percepción remota en un formato que sea fácilmente visualizado e interpretado, y así ganar conocimiento de la Tierra. El primer problema que se encuentra es que la mayoría de los datos de percepción remota que se obtienen de agencias gubernamentales (NOAA) y privadas (EOSAT y SPOT), están en formato digital. Entonces, para convertir los ND guardados en este formato, en una imagen que se aproxime a una fotografía con tonos continuos, es necesaria la creación de un mapa de brillantez, también comúnmente llamado como imagen en escala de grises.

Un *mapa de brillantez* es una gráfica computacional desplegada de los ND_{ijk} (nivel digital o valor de brillantez en el píxel de la línea i , columna j y banda k), que se encuentran en los datos digitales obtenidos por percepción remota. Idealmente existe una relación uno a uno entre los ND y las intensidades de salida en los valores de brillantez que resultan en el despliegue (Fig. 3.5a). Por ejemplo una entrada de ND igual a 0, podría resultar en valor de intensidad de brillantez muy oscuro (negro) en el despliegue de salida, mientras que un ND igual a 255 puede producir un valor muy brillante (blanco) en la intensidad de brillantez. Todos los valores de brillantez entre 0 y 255 podrán ser desplegados en una continua escala de grises que va desde el negro hasta el blanco. Utilizando un sistema como este, un valor de 127 podrá ser desplegado con un valor 127 (gris medio) en la imagen de salida (Fig. 3.5a). Desafortunadamente, no siempre es fácil mantener esta relación ideal. Puede darse el caso de que el dispositivo de salida tenga un rango pequeño de niveles de brillantez (por ejemplo <50, Fig. 3.5b). En este ejemplo, muchos valores de ND alrededor de 127 deben ser asignados a un mismo nivel de brillantez de salida: 25. Cuando esto ocurre, mucha información original es generalizada en el despliegue, perdiéndose valiosa información que no se podrá ver en el análisis de la imagen. En consecuencia, es importante tratar de mantener la relación uno a uno entre los valores de entrada y los valores de salida, siempre que sea posible. A continuación se explicará como se despliegan en el monitor estas imágenes.

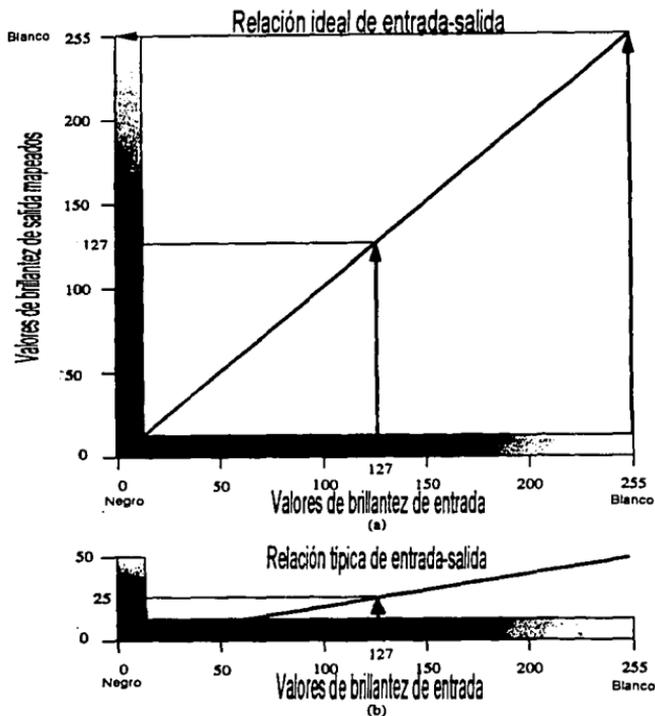


Fig. 3.5 (a) Relación uno a uno ideal entre una entrada de 8 bits de valores de brillantez y los valores de brillantez de salida mapeados. (b) Situación típica en la cual el dispositivo de salida no es capaz de mantener la relación de uno a uno y debe de generalizar los 8 bits de datos originales a un número menor de valores de brillantez mapeados más manejable.

3.4.1 Mapas de brillantez blanco-negro y color

Una imagen de percepción remota desplegada en video puede ser fácilmente modificada y guardada, o bien descartada. El CPU lee los datos del sensor remoto desde algún dispositivo de almacenamiento (CD, disco duro, etc.) y transfiere estos datos al procesador de la imagen.

El *procesador de la imagen* es una colección de memoria a desplegar compuesta por i líneas por j columnas y b bits a la cual se puede tener acceso secuencialmente, línea a línea (Fig. 3.6). Cada línea de valores digitales guardados en la memoria de despliegue del procesador de la imagen es barrida continuamente por el mecanismo de lectura. El contenido de la memoria del procesador de la imagen es leída aproximadamente cada $1/30$ s, dependiendo de la *razón de refresco* del sistema. Los valores de brillantez encontrados durante este proceso de barrido son pasados a un convertidor analógico-digital (DAC, *Digital Analog Converter*) que prepara las señales analógicas de video para su despliegue en un monitor CRT (*Cathode Ray Tube*). En consecuencia el analista observa en el monitor una representación en video de los valores digitales guardados en la memoria del procesador de la imagen.

El hecho de que el rango entero de ND sea desplegado correctamente en video, está en función del número de bits por pixel, el sistema coordenado de color que sea usado y, las tablas de referencia de color asociadas con el procesador de la imagen. Normalmente se asume los datos de percepción remota son cuantificados con 8 bits por pixel (valores de 0 a 255). Sin embargo, algunos sistemas tienen desde 9 hasta 12 bits de resolución radiométrica, así que es importante no dar por hecho este parámetro. En seguida, se debe seleccionar el sistema coordenado de color. Los datos obtenidos por percepción remota son usualmente desplegados usando el *sistema coordenado de color RGB (Red Green Blue)*, el cual está basado en la teoría aditiva del color y en los tres colores primarios: rojo, verde y azul (Fig. 3.7). La teoría aditiva del color está basada en lo que pasa cuando luz con diferentes características de frecuencia es mezclada. Por ejemplo, usando la teoría aditiva del color, se puede obtener un pixel blanco brillante dando valores de RGB de 255, 255 y 255 a cada una de las componentes. En contraparte, podemos obtener píxeles negros usando cantidades iguales de azul, verde y rojo. Usando tres imágenes de 8 bits y la teoría aditiva del color podemos desplegar 2^{24} combinaciones diferentes de color. Por ejemplo, valores de RGB de 255, 255, 0 nos dan como resultado un pixel amarillo brillante, y valores de RGB de 255, 0, 0 nos dan un pixel rojo brillante. Con valores de RGB de 0, 0, 0 obtenemos un pixel negro. Los grises se obtienen a través de la línea de grises en el sistema coordenado de color RGB (Fig. 3.7), cuando se encuentran iguales proporciones de azul, gris y rojo, por ejemplo un gris medio se obtiene con valores de RGB de 127, 127, 127.

La naturaleza exacta del despliegue está controlada precisamente por el tamaño y características de un bloque de memoria separado llamado *tabla de referencia de color*, el cual contiene la disposición exacta de cada combinación de valores de rojo, verde y azul (RGB) asociados a cada uno de los píxeles de 8 bits. Evaluando la naturaleza de un procesador de imagen de 8 bits y su tabla de color asociada (Fig. 3.6), podemos observar el modo en que interactúan los valores de ND de los datos obtenidos por percepción remota y la tabla de referencia de color. En el ejemplo #1 de la Figura 3.6, se puede observar que los primeros 256 elementos de la tabla de referencia de color coinciden con valores de rojo, verde y azul (RGB) que aumentan progresivamente y en cantidades iguales, que van de un valor de 0, 0, 0 que corresponde a un negro en la pantalla, pasando por un valor de 127, 127, 127 que sería un gris, hasta un valor de 255, 255, 255 que representa un blanco brillante. Entonces, si un pixel de una banda tiene un valor de ND de 127 (con valores RGB de 127, 127, 127), éste se representará en la pantalla como un pixel gris-medio. Esa lógica se emplea para crear los mapas de brillantez blanco-negro o de escala de grises. Esta representación se conoce como despliegue real en escala de grises, puesto que existe una relación uno a uno entre los 8 bits de

TESIS CON
FALLA DE ORIGEN

los valores de ND de una banda espectral obtenida a partir de percepción remota y los 8 bits de la tabla de referencia de color (tal y como se muestra en la figura 3.5a). Este es el mecanismo ideal para desplegar datos de percepción remota.

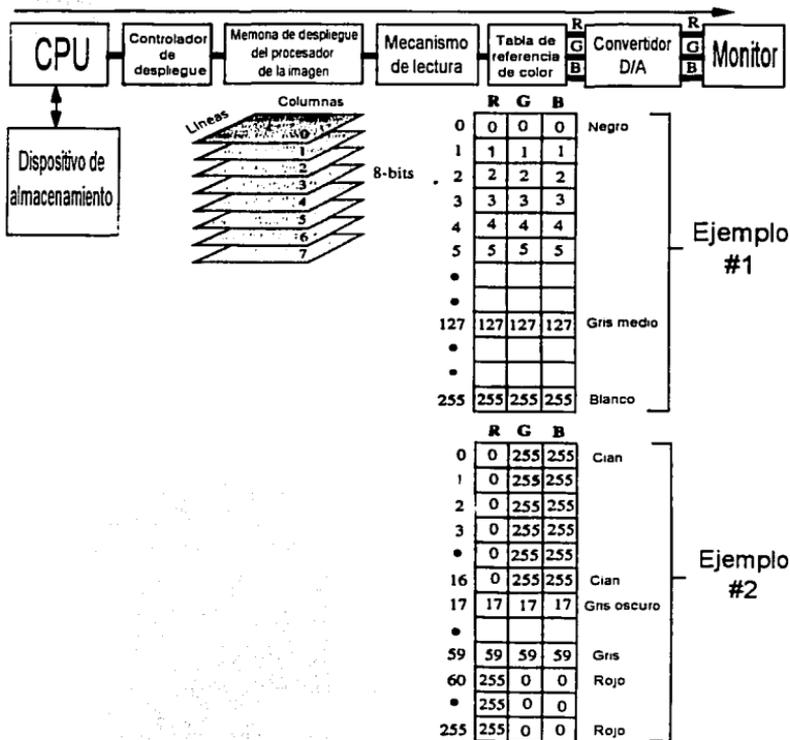


Fig. 3.6 Componentes de un sistema de procesamiento digital de imágenes de 8 bits.

TESIS CON
FALLA DE ORIGEN

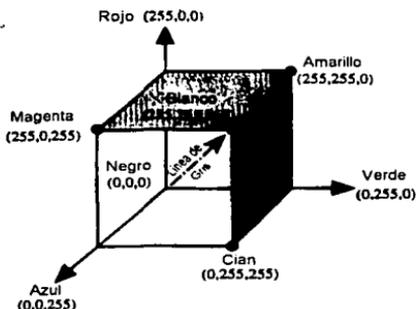


Fig. 3.7 Sistema coordenado de color RGB basado en la teoría aditiva del color.

Se ha puesto en evidencia que el ojo humano es más capaz de distinguir tonos de color que intensidades de brillo. Por lo tanto, el empleo del color puede facilitar notablemente el análisis, tanto visual, como la preparación de otros tratamientos digitales. Se usará el término pseudo-color para indicar aquellos tratamientos donde se diseña artificialmente una tabla de color. Como ya se sabe, cuando se visualiza una imagen en blanco y negro, las columnas para los tres colores primarios (rojo, verde y azul) presentan el mismo valor, puesto que cada tono de gris supone una mezcla en partes iguales de los tres colores primarios. Ahora bien, puede representarse asimismo una sola banda en distintos tonos de color. Basta diseñar una tabla de referencia de color en la cual las tres columnas presenten distintos valores. En otras palabras una tabla de referencia de color que asocie el ND de una sola banda de la imagen a distintos componentes de rojo, verde y azul. Esto puede tener sentido cuando se pretenda obtener una clave de color en una imagen clasificada, o bien cuando se intente realizar la respuesta espectral de algún material en una imagen, sustituyendo los niveles de gris por tonos de color.

Cuando se visualiza una imagen monocromática en distintas tonalidades se emplea propiamente el pseudo-color. El sentido de esta representación visual, como ya se ha dicho, es realzar el análisis de cada banda, facilitando al analista una primera impresión para discriminar el fenómeno objeto de estudio. El pseudo-color puede aplicarse al conjunto de los ND de la escena, diseñando una tabla de referencia de color formada, por ejemplo, por números aleatorios entre 0 y 255, para cada uno de los tres colores. Más frecuente es, sin embargo, aplicar una transformación progresiva, en donde la tabla de referencia de color tiene una dirección determinada de progresión: desde los tonos azules para los ND bajos hasta los rojos, para los más altos, por citar algún ejemplo.

Más sentido tiene, en cambio, aplicar un color a un determinado rango de ND, de tal forma que, por un lado, se simplifica el rango inicial, en un número menor de intervalos, y, por otro, se aplica a éstos un color más fácil de discriminar visualmente que los niveles de gris. En definitiva, se trata de establecer *intervalos de densidad (density slicing)* en cada banda. Este nombre se emplea para indicar, que cada uno de estos grupos corresponde a valores de

radiancia relativamente similares. Los umbrales que definen cada intervalo pueden establecerse arbitrariamente o con algún criterio estadístico: por ejemplo, señalando una anchura constante a partir del rango, o seleccionando intervalos de la misma frecuencia. En cualquier caso, los umbrales elegidos pueden modificarse interactivamente, con lo que el usuario puede detectar, en cada banda, el rango de ND que comprende un fenómeno de interés. En el ejemplo #2 (Fig. 3.6), al primer valor de entrada de la tabla, 0, se le da un valor de RGB de 0, 255, 255, lo cual significaría que cada pixel con valor de 0 sería desplegado en cian (un brillante azul-verde) y así se cambian los valores para crear los intervalos de densidad que podrían estar resaltando rasgos específicos de la imagen. De esta forma es posible crear tablas de referencia de color de propósito especial, con las cuales el analista puede resaltar las características espectrales de los materiales de su interés.

3.4.2 Composiciones en color

A partir de la información multispectral que generan la mayor parte de los sensores espaciales, pueden obtenerse distintas composiciones de color. Basta para ello aplicar cada uno de los tres colores primarios (azul, verde y rojo) a una banda distinta de la imagen, seleccionada con el criterio y en el orden que se estime más oportuno. El proceso permite visualizar, simultáneamente, imágenes de distintas regiones del espectro, lo que facilita la delimitación visual de algunas cubiertas. Por tratarse de bandas distintas, la tabla de referencia de color aplicada a una composición en color presenta tres columnas con distintos valores, cada columna corresponde a una de las tres bandas que intervienen en el proceso.

La elección de las bandas para realizar la composición, y el orden de los colores destinados a cada una, dependen del sensor sobre el que se trabaje y de la aplicación del proyecto. La composición más habitual es la que es denominada falso color de infrarrojo, que se genera al aplicar los canales de color rojo, verde y azul sobre las bandas correspondientes al infrarrojo cercano, rojo y verde, respectivamente. Esta composición facilita la cartografía de masas vegetales, cuerpos de agua, ciudades, etc., de ahí que se emplee mucho en diversos estudios de análisis visual.

El sensor TM (o el ETM), dotado de 7 bandas espectrales, ofrece la posibilidad de realizar un amplio número de composiciones de falso color. Se han desarrollado diversos métodos para seleccionar la combinación que contenga un mayor contenido informativo. Se trata de identificar la composición multi-banda que, entre las 35 posibilidades de combinaciones de 3 bandas (20 si no se toma en cuenta la banda del infrarrojo térmico), realce mejor las coberturas del conjunto de la imagen. Una forma de selección parte de retener las tres bandas con un mayor contenido de la varianza original. De esta forma se define el *índice óptimo* (*Optimum Index Factor, OIF*):

$$OIF = \frac{\sum_{k=1}^3 s_k}{\sum_{j=1}^3 Abs(r_j)} \quad [3.10]$$

donde s_k indica la desviación estándar de cada una de las tres bandas que intervienen en la composición y r_j el coeficiente de correlación entre cada par de esas mismas bandas (Jensen, 1996).

3.5 Realce de la imagen

Los algoritmos para el realce de la imagen son aplicados a los datos de percepción remota para mejorar la apariencia de la imagen, ya sea para el análisis visual o para un subsiguiente análisis hecho por computadora. No se puede generalizar acerca de cual es la mejor técnica de realce, debido a que los resultados serán finalmente evaluados por humanos, quienes en general hacen juicios subjetivos acerca de éstos. Por otro lado, en el caso de que los datos sean ocupados para análisis subsiguientes hechos por computadora, la decisión de utilizar alguna de las técnicas dependerá de la finalidad con la cual se realicen el realce de la imagen. Se pueden identificar dos tipos de operaciones de realce de la imagen (Jensen, 1996): puntuales y locales.

Las operaciones puntuales modifican los valores de brillantez de cada uno de los píxeles del conjunto de datos de la imagen independientemente. Las operaciones locales modifican el valor de cada uno de los píxeles tomando en cuenta del contexto de los valores de brillantez que lo rodean.

Por último es muy importante mencionar que, en el caso de que se estén preparando las imágenes para posteriores procesos computacionales, se deben de aplicar las técnicas de realce con mucho cuidado, pues en la mayoría de los casos (como lo son las técnicas de clasificación) se requiere que los datos se encuentren en su forma original.

3.5.1 Cambios de escala

Es muy importante manejar con cierta precaución el concepto de escala cuando se habla de sensores óptico-electrónicos. La escala final de la imagen está en función del tamaño con el que se representa el píxel, unidad mínima de información. Ahora bien, la superficie real que ocupa el píxel es la misma, así como el ND que lo define, independientemente del tamaño con el que éste se represente sobre el monitor o el papel.

Hecha esta aclaración, obvia decir que en muchas situaciones el tratamiento digital de imágenes requiere aumentar o disminuir el tamaño del píxel en pantalla. Por cuanto la resolución física del monitor es constante (sólo admite un número determinado de píxeles), el

cambio de escala debe realizarse a través del muestreo o duplicación de los píxeles que componen la imagen.

Si se pretende visualizarse un área con un número de píxeles superior a la capacidad de la pantalla, basta seleccionar una muestra de la imagen original. En pocas palabras, se trata de escoger uno de cada dos, tres o cuatro píxeles en la imagen, para que pueda visualizarse sobre el monitor un área cuatro, nueve o dieciséis veces más grande (Fig. 3.8). Naturalmente que esto supone hacerlo con menos detalle, ya que se está seleccionando sólo una parte de los ND originales. Sin embargo, el proceso es muy útil en algunas instancias: por ejemplo, cuando se pretende localizar una pequeña área de estudio sobre una escena completa.

El proceso contrario a la reducción se denomina magnificación, ampliación, o, simplemente *zoom*. Se trata de ampliar el tamaño del píxel sobre el monitor, con objeto de estudiar una parte de la imagen con mayor detalle. Constituye una de las opciones más frecuentes en tratamiento digital, puesto que facilita operaciones muy comunes como el establecimiento de campos de entrenamiento (muy útil para la clasificación de imágenes).

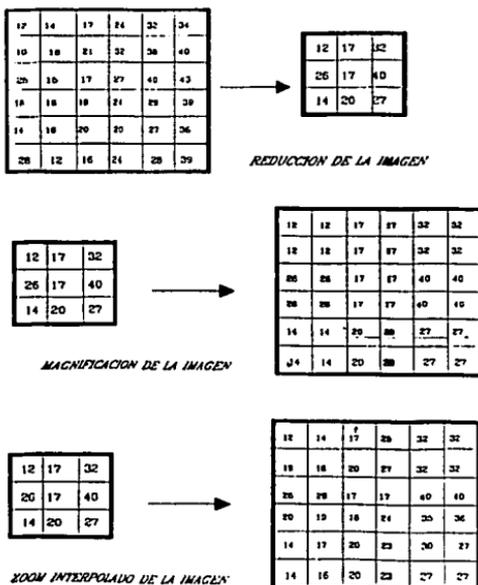


Fig. 3.8 Efectos de los cambios de escala.

TESIS CON
FALLA DE ORIGEN

La ampliación suele realizarse en la memoria del procesador de imagen o tarjeta gráfica. En realidad los píxeles mantienen su posición y valor; sólo cambian su tamaño sobre la pantalla. Esta forma de zoom (vía hardware) es rápida e interactiva: puede magnificarse la imagen repetidas veces, retornando rápidamente, y en cualquier momento, al tamaño original.

Realizar un zoom mediante instrucciones de programa resulta más tedioso, aunque es un proceso bastante trivial. Basta reduplicar cada píxel tantas veces como se pretenda ampliar el área visualizada (Fig. 3.8). Este criterio, al igual que el zoom por hardware, acaba por hacer patente la forma rectangular de los píxeles. La imagen pierde, entonces su nitidez espacial y puede mostrar un trazado muy geométrico. Una ampliación de mayor calidad visual puede lograrse mediante un zoom interpolado. Aquí, en lugar de una simple replicación de los ND originales, se crea una nueva matriz de tamaño equivalente al nivel de magnificación. En esta matriz se sitúan los ND originales, y se calculan los otros por interpolación lineal de estos valores. La impresión que causa sobre la pantalla es la de una imagen mucho más nítida, puesto que mantiene una mejor transición entre píxeles vecinos.

3.5:2 Realce del contraste

Los sensores remotos graban el flujo radiante reflejado y emitido que proviene de los materiales superficiales de la Tierra. Idealmente, un material debería reflejar una gran cantidad de energía en una cierta longitud de onda, mientras otro material reflejaría mucho menos energía en esa misma longitud de onda. Esto nos daría como resultado en un *contraste* entre los dos tipos de materiales. Desafortunadamente, materiales distintos frecuentemente reflejan cantidades similares de flujo radiante a través de las porciones visible, infrarroja cercana e infrarroja media del espectro electromagnético, dando como resultado una imagen relativamente baja en contraste. Además, aparte de estas obvias características biofísicas de los materiales que provocan bajo contraste, hay factores culturales que también influyen. Por ejemplo, en los países en desarrollo, frecuentemente se usan materiales naturales de construcción (como lo son la madera y el barro) en las áreas urbanas. Esto provoca que las imágenes de estas áreas, obtenidas a partir de sensores remotos, tengan un contraste mucho mas bajo que las imágenes obtenidas en áreas urbanas de países desarrollados, en los cuales se ocupa principalmente el asfalto, el concreto y las áreas de vegetación verde son fertilizadas, con lo cual aumenta su contenido de clorofila y su reflectancia en el infrarrojo cercano.

Un factor adicional que provoca un bajo contraste en imágenes de percepción remota, es la sensibilidad de los sensores. Por ejemplo, los sensores, en la mayoría de los sistemas, están diseñados para grabar una escena con un rango relativamente amplio de valores de brillantez (0 a 255) sin que éstos se saturen. La saturación ocurre cuando la sensibilidad radiométrica del sensor es insuficiente para grabar el rango completo de intensidades de energía, ya sea reflejada o emitida, que emanan de la escena. Los sensores TM del Landsat, por ejemplo, deben ser sensibles de reflejar distintos materiales, como lo son el basalto volcánico oscuro o la nieve (posiblemente representados como valores de brillantez de 0 y 255 respectivamente). Sin embargo, muy pocas escenas están compuestas por valores de brillantez que utilizan el rango completo de sensibilidad de los sensores TM del Landsat. Por

consecuente, las imágenes tienen un bajo contraste, con valores que usualmente se encuentran dentro de un rango de 0 a 100.

Para mejorar el contraste de una imagen digital obtenida a partir de la percepción remota, es deseable que se emplee el rango completo de valores de brillantez que nos ofrece el medio de despliegue. Con esta finalidad, se ha encontrado que los métodos digitales son más satisfactorios que los métodos fotográficos, debido a la mejor precisión y a la amplia gama de procesos que pueden ser aplicados a las imágenes.

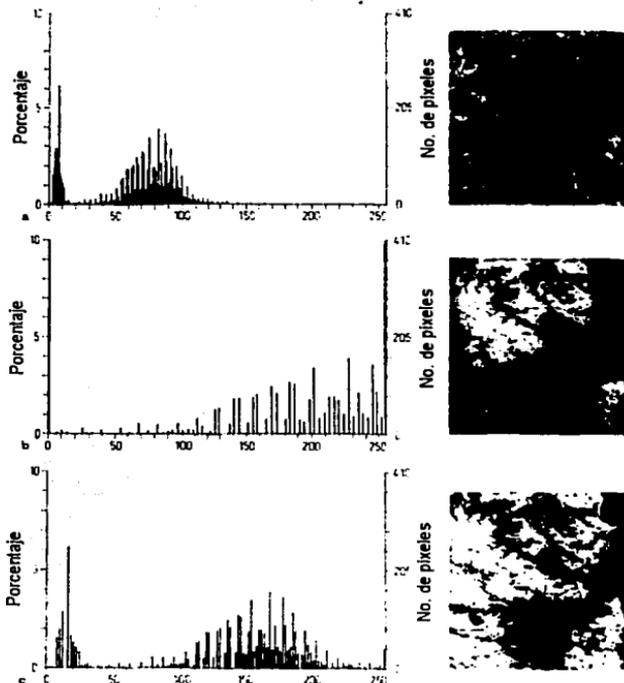


Fig. 3.9 Ejemplos de histogramas de imágenes. La imagen en **a** muestra un contraste pobre debido a que su histograma utiliza un rango restringido de valores de brillantez. La imagen en **b** tiene mucho contraste con saturación en las regiones de blanco y negro, lo que da como resultado una pérdida de contraste y detalles. La imagen en **c** tiene un uso óptimo de los valores de brillantez disponibles y presenta un buen contraste. Su

histograma muestra una buena dispersión de las barras, evitando también barras largas en el negro y en el blanco, lo cual indica la saturación en la imagen b.

Antes de presentar específicamente algunas de las técnicas más comunes de realce, se verán algunos conceptos introductorios.

Considerando el caso de una imagen espacial con valores escalares y cuantificados, como lo es una imagen de alguna de las bandas multispectrales del Landsat, en este caso los valores de brillantez están también cuantificados. Si cada píxel de la imagen es examinado y su valor de brillantez anotado, podemos construir una gráfica con el número de píxeles con ciertos valores de brillantez contra los valores de brillantez. Esto, como ya lo hemos visto, es el histograma de la imagen. La calidad tonal o radiométrica de una imagen puede ser asignada a un histograma tal y como se ilustra en la figura 3.9. Una imagen que hace uso de los rangos de valores de brillantez disponibles tiene un histograma que ocupa barras sobre su rango completo de valores, pero sin un significativo uso de barras largas en blanco o negro.

Una imagen tiene un único histograma, pero lo contrario no es cierto, debido esto a que generalmente, un histograma contiene solo información radiométrica y no información espacial. Un aspecto importante, es que el histograma de una imagen puede ser visto como una distribución de probabilidad discreta, debido a que la altura relativa de una barra en particular, indica la posibilidad de encontrar un píxel con ese valor de brillantez en algún otro lugar de la imagen. En asociación a este término se encuentra el de histograma acumulado, o distribución de probabilidad discreta acumulada, el cual es una gráfica del número total de píxeles que se encuentran debajo de un umbral de nivel de brillantez contra el umbral de nivel de brillantez (Fig. 3.10).

Esto es útil para comprobar si el histograma es considerado como una función continua con valores de brillantez que varían de forma continua. Si bien este no es el caso para las imágenes digitales, como concepto puede simplificar algunas derivaciones y conducir a resultados que son fácilmente interpretados de forma digital. Una función histograma continua $h(x)$ se ilustra en la figura 3.11, donde x es la variable continua que representa valores de brillantez, y h representa el valor del histograma discreto en esa brillantez. Estrictamente la altura de la barra en el histograma discreto sería $h(x) dx$ donde dx es el incremento en los valores de brillantez. Cuando el número de valores de brillantez es muy grande $dx \approx 1$. Aunque en general puede ser presentado como $dx = (L - 1) / L$ donde L es el número total de valores de brillantez.

En términos estadísticos $h(x)$ es la función de densidad de probabilidad y $\int_0^1 h(x) dx$ es la función de probabilidad acumulada.

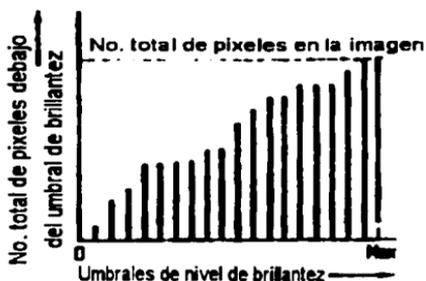
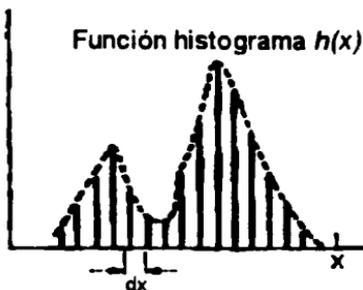


Fig. 3.10 Histograma acumulado.

Fig. 3.11 Descripción de la función histograma continuo $h(x)$ y su relación con el histograma discreto cuando $dx = 1$.

Supóngase que se tiene disponible una imagen con un contraste pobre, como la imagen mostrada en la figura 3.9a y se desea mejorar su contraste para obtener una imagen con un histograma que tenga una buena distribución de barras sobre todo el rango disponible de valores de brillantez, tal y como se muestra en la figura 3.9c. En otras palabras, se requiere una *expansión del contraste* de los datos de la imagen. Frecuentemente el grado de expansión deseado es evidente. Por ejemplo el histograma original puede ocupar valores de brillantez entre 40 y 50, y debería de ser deseable expandir este rango hasta su máximo posible, es decir de 0 a 255. Aunque la modificación es un tanto obvia, es necesario expresarla en términos matemáticos, en orden de relegarle el cálculo de ésta a la computadora. La modificación del

contraste es un mapeo de valores de brillantez, en el que los valores de brillantez de un histograma de barras en particular son reespecificados más favorablemente. Si bien las barras en sí mismas no son modificadas, en algunos casos algunas barras pueden ser mapeadas en un mismo nuevo valor de brillantez, quedando así sobrepuestas. En general, sin embargo, el nuevo histograma tendrá barras en localizaciones diferentes.

El mapeo de valores de brillantez asociado con la modificación del contraste puede ser descrita como $y = f(x)$, donde x es el antiguo valor de brillantez de una barra en particular en el histograma, y y es el nuevo valor de brillantez correspondiente. Se llamará $h_i(x)$ la función histograma de la imagen original, y $h_o(y)$ la función histograma de la imagen con el contraste modificado. En este caso los subíndices i y o tienen una connotación referente al histograma de entrada ("input") a un proceso de modificación de contraste, y el histograma resultante de salida ("output"), respectivamente. El diseño de un proceso de modificación radiométrica de una imagen, se obtiene de la respuesta a ésta incógnita: conociendo $h_i(x)$ y $y = f(x)$, ¿Cuál es la forma de $h_o(y)$? La respuesta se puede obtener en referencia a la figura 3.12.

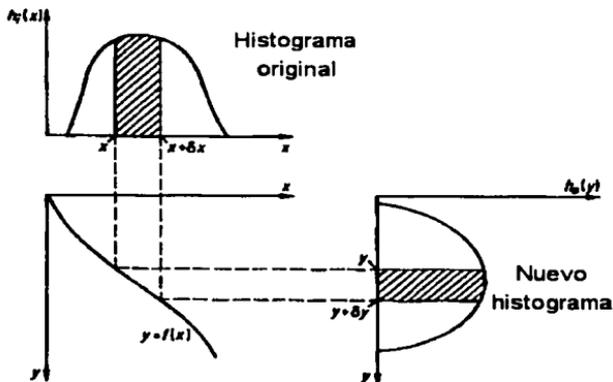


Fig. 3.12 Representación esquemática de la modificación del contraste por la función de mapeo de los valores de brillantez $y = f(x)$.

En la figura 3.12 el número de píxeles representado por el rango y a $y + \delta y$ en el histograma modificado debe de ser, por definición en el diagrama, igual al número de píxeles representados por el rango x a $x + \delta x$ en el histograma original. Dado que $h_i(x)$ y $h_o(y)$ estrictamente son funciones de densidad, esto implica que

$$h_i(x) \delta x = h_o(y) \delta y$$

dado que en el límite δx , $\delta x \rightarrow 0$

$$h_o(y) = h_i(x) \frac{dx}{dy} \quad [3.11]$$

De $y = f(x)$, $x = f^{-1}(y)$ y [3.11] tenemos que

$$h_o(y) = h_i(f^{-1}(y)) \frac{d(f^{-1}(y))}{dy} \quad [3.12]$$

la cual es la expresión analítica para el histograma de salida.

Hay que tomar en cuenta que, matemáticamente, se requiere la existencia de la inversa $x = f^{-1}(y)$. En el caso de los procedimientos de modificación de contraste usados con imágenes de percepción remota, generalmente no se tienen problemas de este tipo, particularmente en las situaciones para las cuales se ocupa la ecuación [3.12].

3.5.2.1 Realce lineal del contraste

Para ilustrar una modificación del contraste, se considerará una simple variación lineal descrita por

$$Y = f(x) = ax + b$$

de tal forma que

$$x = f^{-1}(y) = (y - b) / a,$$

y

$$d f^{-1}(y) / dy = 1 / a.$$

Entonces, el histograma modificado, obtenido de [3.12] es

$$h_o(y) = \frac{1}{a} h_i\left(\frac{y-b}{a}\right) \quad [3.13]$$

En relación al histograma original, la versión modificada esta desplazada debido al efecto de b , es expandida o comprimida dependiendo de que si a es mayor o menor a 1 y está modificada en su amplitud. Este último efecto está relacionado solamente a la función histograma continua y no ocurre cuando los datos son valores de brillantez discretos. Un ejemplo numérico de una modificación lineal del contraste se muestra en la figura 3.13, un ejemplo donde una imagen con un pobre contraste ha sido realizada radiométricamente mediante una amplificación lineal del contraste, se muestra en la figura 3.14.

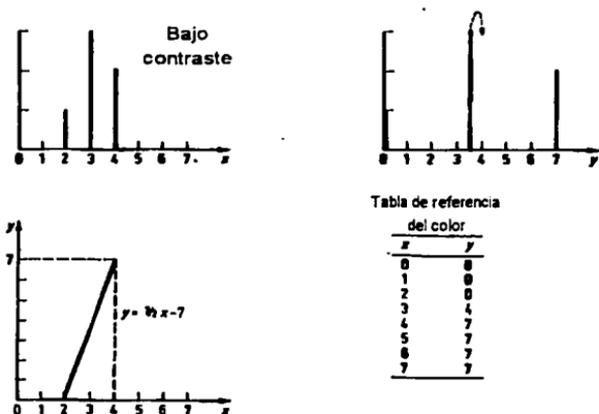


Fig. 3.13 Sencillo ejemplo numérico de una modificación lineal del contraste. El rango disponible de valores discretos de brillantez va de 0 a 7. En este caso, los valores de brillantez que no son enteros están indicados. En la práctica estos valores se redondean al valor entero más cercano.

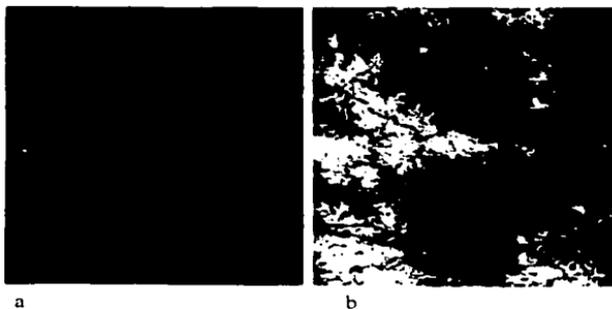


Fig. 3.14 La modificación lineal del contraste de **a**, produce un producto visualmente mejor en **b**.

La tabla de referencia de color para la amplificación lineal que se muestra en la figura 3.13, ha sido incluida en la figura. En la práctica esto puede ser ocupado por una rutina computacional para producir una nueva imagen. Esta rutina debe de realizar una lectura de los valores de brillantez de la versión original, píxel por píxel, para buscar este valor en el lado izquierdo de la tabla y así luego asignar el nuevo valor de brillantez, el cual será el correspondiente al lado derecho de la tabla. Es importante notar que, en el manejo de la imagen digital, los nuevos valores de brillantez, así como los viejos, deben ser discretos, y usualmente cubrir el mismo rango de valores de brillantez. Generalmente esto requerirá de un redondeo entero para estos nuevos valores de brillantez calculados mediante la función de mapeo $y = f(x)$. Otro detalle adicional que se puede observar en el ejemplo de la figura 3.13, es que la tabla de referencia de color no está definida para valores fuera del rango de entradas que van de 2 a 4. El hacer esto puede generar valores de brillantez que estén fuera del rango valido para éste ejemplo. En la práctica, una ampliación lineal del contraste se implementa generalmente como una ampliación lineal del contraste con saturación, el cual se verá en la siguiente sección.

3.5.2.2 Realce lineal del contrastes con saturación

Frecuentemente, se da una mejor imagen cuando se usa un realce lineal del contraste dándole un cierto grado de saturación de blanco y negro al final del histograma. Es el caso, por ejemplo, si las regiones oscuras de una imagen corresponden al mismo tipo de cobertura terrestre, en las cuales las pequeñas variaciones radiométricas no son de interés. De forma similar, cuando una región particular de interés en una imagen ocupa un rango restringido de valores de brillantez, se usa un realce lineal del contraste con saturación para expandir tal rango dinámico al máximo posible del dispositivo de despliegue, siendo mapeadas todas las otras regiones ya sea en blanco o en negro. La función de mapeo de valores de brillantez $y = f(x)$ para el realce lineal del contraste con saturación se muestra en la figura 3.15, en la cual B_{max} y B_{min} son los valores máximo y mínimo de valores de brillantez determinados por el usuario, que serán usados para expandir con los niveles mas bajos y los mas altos soportados por el dispositivo de despliegue.

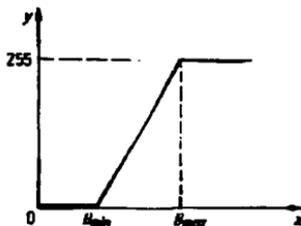


Fig. 3.15 Mapeo lineal del contraste con saturación.

Los sistemas de despliegue de imágenes frecuentemente implementan lo que se ha llamado alargamiento (*stretch*) del contraste automático, en orden de darle a la imagen un mejor contraste. Típicamente el procedimiento de realce automático es un alargamiento lineal con saturación. Los límites de corte y de saturación B_{min} y B_{max} son elegidos determinando la media de los valores de brillantez de la imagen original y su desviación estándar; haciendo B_{min} igual a la media menos tres veces la desviación estándar y B_{max} igual a la media mas tres veces la desviación estándar.

3.5.2.3 Realce del contraste logarítmico y exponencial

Los mapeos logarítmicos y exponenciales de valores de brillantez entre las imágenes original y modificada, son útiles para realizar aspectos oscuros y luminosos, respectivamente. Las funciones de mapeo son descritas en la figura 3.16, junto con sus expresiones matemáticas. En estos mapeos se cuida que los valores de salida sean escalados de forma tal que sus nuevos valores estén siempre dentro de los rangos del dispositivo de salida y que éstos sean redondeados a valores discretos.

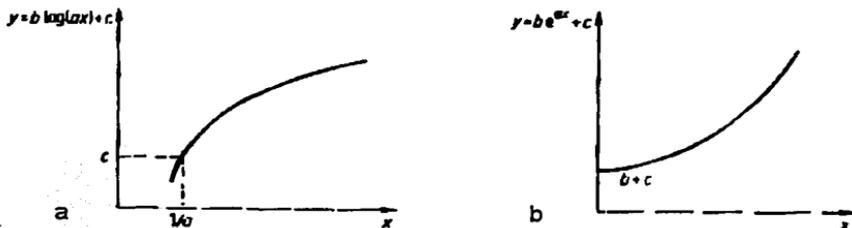


Fig. 3.16 Funciones de mapeo de brillantez logarítmica (a) y exponencial (b). Los parámetros a , b y c , son incluidos frecuentemente para ajustar los valores de contraste y brillantez de la imagen de salida.

3.5.2.4 Ecuación del histograma

En las secciones anteriores se ha visto el realce de una imagen como una simple expansión o contracción del histograma de la imagen. En muchas situaciones, sin embargo, es deseable modificar el contraste de una imagen de forma que este siga o tome una forma determinada, o bien se acerque bastante a una simple modificación matemática de la versión original. Una forma particular e importante es la del histograma uniforme, en la cual, en principio, cada barra tiene la misma altura. Como un histograma, tiene asociada una imagen en la cual se

ocupan todos los valores de brillantez de igual manera (con la misma altura todas las barras), esto nos daría como resultado una imagen en la cual hay una buena representación de detalle en todos los valores de brillantez. En la práctica, un histograma con valores perfectamente uniformes, no es posible para una imagen digital; el procedimiento, sin embargo, produce un histograma casi uniforme en su promedio. El método de generar un histograma uniforme es conocido generalmente como ecualización del histograma.

Como antes, será $h_i(x)$ la función original del histograma y $h_o(y)$ la representación del histograma modificado, el cual es uniforme. Si la imagen contiene un total de N píxeles y hay L barras o valores de brillantez en el histograma, entonces cada valor de brillantez en el histograma modificado deberá tener barras de N/L píxeles asociadas con él. Recordando también que cada barra en un histograma discreto tiene valores de $h_o(y) dy$. En el caso de L valores de brillantez disponibles, $dy = (L - 1) / L$, entonces para un histograma uniforme

$$h_o(y) (L - 1) / L = N / L$$

resultando $h_o(y) = N / (L - 1)$. De [3.11] tenemos entonces

$$\frac{dy}{dx} = \frac{d}{dx} \{f(x)\} = \frac{L-1}{N} h_i(x)$$

en el cual $y = f(x)$ es el mapeo solicitado o la transformación de valores de brillantez que nos convierte el histograma original en una imagen con un histograma uniforme. Consecuentemente

$$y = f(x) = \frac{L-1}{N} \int h_i(x) dx \quad [3.14]$$

La transformación de la ecualización del histograma es entonces, la integral de la función histograma original. La integral es, justamente, el histograma acumulado continuo; el cual puede ser reemplazado por el histograma acumulado discreto en el caso de una imagen con valores de brillantez cuantificados, en cuyo caso [3.14] producirá una tabla de referencia que puede ser usada para mover las barras del histograma a nuevas posiciones de valores de brillantez. Para ilustrar este concepto se considerará la necesidad de "aplanar" un histograma simple, mostrado en la figura 3.17a. Este corresponde a una hipotética imagen con 25 píxeles, los cuales pueden tomar uno de los 16 posibles valores de brillantez. El correspondiente histograma acumulado se muestra en la figura 3.17b, y el factor de escalamiento en [3.13] es $(L - 1) / N = 15 / 24 = 0.625$. De acuerdo a [3.14], la posición del nuevo valor de brillantez para la barra del histograma se obtiene buscando su posición original en la abscisa del histograma acumulado (x) y leyendo entonces su nueva posición sin escalar (y) desde la ordenada. Luego se multiplica por el factor de escalamiento para obtener el nuevo valor requerido. Sin embargo, este nuevo valor puede no estar dentro de un valor de brillantez discreto disponible, en cuyo caso se mueve la barra al valor de brillantez disponible más cercano. Este procedimiento está resumido, para el ejemplo que se ha dado, en la tabla 3.7, y el nuevo histograma con forma casi uniforme se presenta en la figura 3.17c. Es importante enfatizar que no se pueden crear nuevos valores de brillantez adicionales, como tampoco se

pueden distribuir píxeles de un solo valor de brillantez en el histograma original sobre distintos valores de brillantez en la versión modificada. Todo lo que se puede hacer, es remapear los valores de brillantez para obtener un histograma lo más uniforme posible. Algunas veces esto implica que algunas barras del histograma original sean movidas a una misma nueva ubicación y, de esa forma, sean sobrepuestas, tal y como se observa en el ejemplo.

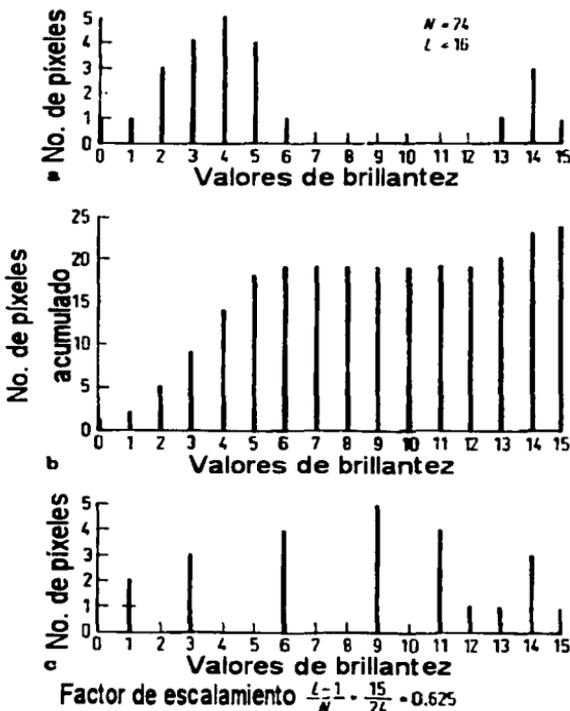


Fig. 3.17 Ejemplo de una equalización del histograma. a Histograma original; b Histograma acumulado usado para producir la tabla de referencia del color en la tabla 3.7; c el histograma resultante cuasi-uniforme.

Tabla 3.7 Tabla de referencia del color para el ejemplo de ecualización del histograma.

Valores de brillantez originales	Nuevos valores sin escalar	Nuevos valores escalados	Valores de brillantez disponibles más cercanos
0	1	0.63	1
1	2	1.25	1
2	5	3.13	3
3	9	5.63	6
4	14	8.75	9
5	18	11.25	11
6	19	11.88	12
7	19	11.88	12
8	19	11.88	12
9	19	11.88	12
10	19	11.88	12
11	19	11.88	12
12	19	11.88	12
13	20	12.50	13
14	23	14.40	14
15	24	15.00	15

En la práctica, la tabla de referencia creada en la tabla 3.7 puede ser aplicada a cada píxel en la imagen, alimentado en la tabla el valor original de brillantez para cada píxel y leyendo de ésta el nuevo valor de brillantez. Cuando la integral en [3.14] se toma como la función histograma acumulado, se puede hacer una simple interpretación. En este caso el valor máximo de la integral es N , o sea, el número total de píxeles en la imagen. El efecto del denominador N en [3.14] es, en consecuencia, el de normalizar la altura del histograma acumulado en la unidad. El múltiplo $L - 1$ en [3.14], entonces escala el eje vertical del histograma acumulado al máximo de $L - 1$. Esto mismo ocurre en el eje horizontal ($L - 1$ es la brillantez máxima de L valores comenzando de cero e incrementándose por 1), por lo que el histograma acumulado resultante es una función de mapeo de valores de brillantez reales, correctamente escalados.

No es necesario mantener el mismo número de valores de brillantez distintos en el histograma ecualizado que en el original. Algunas veces es deseable tener un conjunto más pequeño y en consecuencia producir un histograma con menos barras que son más cercanas en altura que en otros casos. Esto se logra redefiniendo L en [3.14] para que este sea el nuevo número total de barras.

3.5.3 Filtros espaciales

Las técnicas de filtraje, son las correspondientes al tipo de realce local, es decir no solamente toman el píxel en particular, si no también el conjunto de píxeles que rodean su localidad o su contexto. A continuación se presentarán las generalidades del filtrado espacial, pues estas técnicas corresponden solamente al dominio del espacio. También existen técnicas en el dominio de la frecuencia, pero estas no serán tomadas en cuenta en el presente trabajo, aunque si se desea consultarlas esto puede hacerse en otras fuentes (Richards 1993, Jensen 1996).

3.5.3.1 Naturaleza de un filtro digital espacial

Al igual que en las técnicas fotográficas convencionales, el filtro se aplica en análisis digital para aislar componentes de interés. En este caso, los filtros aplicados sobre la imagen pretenden suavizar o reforzar los contrastes espaciales presentes en los niveles de brillantez o niveles digitales (ND) que la componen. En otras palabras, se trata de transformar los ND originales, de tal forma que se asemejen o diferencien más de los correspondientes a píxeles vecinos.

Se han incluido los filtros digitales en este trabajo, porque las técnicas de filtraje se dirigen al realce visual de la imagen, y también, como se verá más adelante, pueden servir para preparar o mejorar las técnicas de clasificación de imágenes. Al igual que las operaciones antes comentadas, pretenden mejorar la visualización de las imágenes, ya sea para eliminar valores anómalos, o para resaltar rasgos lineales de interés. Sin embargo, el filtraje implica modificar los niveles originales de brillantez, y no sólo la forma en que se representan visualmente. En otras palabras, no se trata sólo de transformar los niveles de brillantez almacenados en las tablas de referencia de color, sino los ND de la imagen. Por tanto, si pretende abordarse una clasificación digital, las imágenes filtradas no resultan, en principio, muy convenientes, aunque refuercen visualmente rasgos de interés respecto a la imagen original.

De acuerdo al objetivo que se persiga, suelen distinguirse dos tipos de filtros:

- i. Filtros de pasa bajas (*low pass filtering*), que tienden a aislar el componente de homogeneidad en la imagen, seleccionando áreas donde la frecuencia de cambio es baja.
- ii. Filtros de pasa altas (*high pass filtering*), dirigidos a los componentes de alta frecuencia: esto es, a aquellas áreas de alta variabilidad, donde el contraste espacial es intenso.

Ambos tipos de filtrado pueden abordarse con el mismo método. Si el objetivo último es poner a los píxeles de la imagen en relación con sus vecinos (ya sea para homogeneizarlos, o para diferenciarlos), basta realizar una serie de operaciones aritméticas entre cada uno de ellos y sus inmediatos. La forma concreta de efectuar este proceso es aplicar sobre los ND originales una matriz móvil de coeficientes de filtraje (CF). Esta matriz (denominada por

algunos autores, *kernel*) puede tener un tamaño variable, en función del número de píxeles vecinos que queramos implicar en el proceso. Lo habitual es que se trate de una matriz de 3×3 CF, que se aplica sucesivamente a todos los píxeles de la imagen. Puede también disponerse de matrices de filtraje mayores, de 5×5 ó 7×7 píxeles. Cuanto mayor sea ésta, el efecto de suavizado o realce espacial es más intenso, al considerar un mayor número de píxeles vecinos.

En cualquier caso, la matriz de CF se aplica sucesivamente a la imagen original, desplazándose un píxel en cada paso. Conviene insistir que sólo se modifica el ND del píxel central, entre los que son afectados en cada momento por la matriz de filtraje. El sentido de esa transformación depende del tipo de CF señalados por el usuario. Si éstos tienden a ponderar el valor central en detrimento de los externos, el píxel refuerza sus diferencias frente a los vecinos. Por el contrario, si los coeficientes favorecen a los píxeles externos, el central se asemejará más a los adyacentes. Obvia decir que en el primer caso nos encontraríamos ante un filtro de pasa altas, mientras en el segundo sería de pasa bajas.

El procedimiento matemático del filtraje consiste en relacionar cada píxel con sus vecinos, de acuerdo a unos coeficientes determinados por el usuario. Estos marcan, en última instancia, las consecuencias del filtraje. En el caso de una matriz de 3×3 CF, la fórmula genérica sería:

$$ND'_{ij} = \left(\sum_{p=-lq=-1}^1 \sum_{c=s+q}^1 ND_{i+p,j+c} CF_{f+p,c+q} \right) / \sum_{p=-lq=-1}^1 \sum_{c=s+q}^1 CF_{f+p,c+q} \quad [3.15]$$

en donde ND_{ij} indica el ND original del píxel i, j ; ND'_{ij} el ND de salida para ese mismo píxel; CF , el coeficiente de filtraje correspondiente, y f y c la fila y columna central de la matriz de filtraje. El resultado de esta fórmula se aproxima al entero más cercano.

El proceso abordado en un filtraje puede ilustrarse con un sencillo ejemplo. Se pretende aplicar un filtro pasa bajas a una pequeña imagen de 5×6 píxeles, empleando la fórmula anterior sobre una matriz de 3×3 CF (Fig. 3.18). Este sencillo ejemplo sirve para extraer algunas consideraciones de interés. En primer lugar, se observa que el área filtrada se limita a los píxeles centrales. Los píxeles de borde no se afectan por el proceso, puesto que no tienen los 8 vecinos necesarios para realizar el cálculo. Esta característica es común a cualquier filtraje, ya sea pasa altas o pasa bajas. Obviamente, en el caso de una imagen de mayor tamaño (512×512 píxeles, por ejemplo), la pérdida de esos píxeles de borde no supone una grave inconveniencia. Cabe señalar que en una matriz de filtraje de 3×3 se pierden la primera y última fila y columna. Si empleamos matrices de mayor tamaño, la merma será más significativa: con 5×5 , se perderían las dos primeras y últimas; con 7×7 las tres, etc. Otros autores prefieren aplicar algún promedio especial a estos píxeles, en lugar de igualarlos a cero.

TESIS CON
FALLA DE ORIGEN

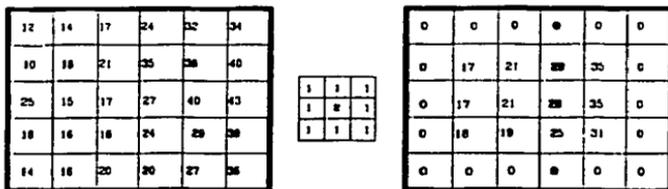


Fig. 3.18 Ejemplo de filtraje,

Volviendo al ejemplo, el nuevo ND del pixel central se calcula por un promedio de los 8 vecinos, con una pequeña ponderación del valor central. Los coeficientes se han aplicado a todos los píxeles centrales de la imagen. Por ejemplo, el situado en la fila 3, columna 3, con un ND inicial de 17 se convierte en la nueva imagen en:

$$ND'_{3,3} = (18+21+35+15+(2 \times 17)+27+16+18+24)/10 = 2.8 \approx 21$$

que es un valor más cercano al sector oriental de la imagen, con valores bajos. De igual forma se procede con el resto de los píxeles hasta obtener la imagen filtrada. El contraste global se ha reducido: mientras la desviación estándar original de los 12 píxeles afectados por el filtraje es 8.91, la correspondiente a los filtrados es 6.77, lo que indica una mayor homogeneidad en la nueva imagen. Un efecto más claro se hubiera obtenido al analizar una mayor superficie y/o aplicar un promedio simple en la matriz de CF. Un proceso similar se emplearía para cualquier otro tipo de filtraje.

3.5.3.2 Filtros pasa bajas

Tienen por objetivo suavizar los contrastes espaciales presentes en la imagen. En breves palabras, se trata de asemejar el ND de cada pixel al de los píxeles vecinos, reduciendo la variabilidad espacial de la escena. En términos visuales, esto supone que la imagen filtrada ofrece perfiles menos nítidos, más difuminados.

Este tipo de filtraje se utiliza para restaurar los errores aleatorios que pueden presentarse en los ND de la imagen. fruto de un defecto en la adquisición o recepción de los datos. Asimismo, se ha empleado para reducir la variabilidad espacial de algunas categorías, como paso previo a la clasificación. En este caso, se pretende atenuar el denominado "ruido de la escena", producido en las zonas altamente heterogéneas en relación con la resolución espacial del sensor. El caso más claro, y el más estudiado, es el que se produce en las zonas urbanas, en donde se mezclan distintos tipos de cubierta en un reducido espacio. Para disminuir esta variabilidad espacial, se han propuesto diversos filtros pasa bajas, que tienden a

homogeneizar los ND de esas zonas. El efecto de estos filtros ha mostrado ser bastante eficiente para la clasificación digital.

El filtro pasa bajas puede obtenerse a partir de diversas matrices de filtraje. Algunas de las más habituales son:

	1.00	1.00	1.00		0.25	0.50	0.25		1.00	1.00	1.00
(1)	1.00	1.00	1.00	(2)	0.50	1.00	0.50	(3)	1.00	2.00	1.00
	1.00	1.00	1.00		0.25	0.50	0.25		1.00	1.00	1.00

La primera es un simple promedio de los 9 píxeles que componen la ventana de filtraje, mientras las dos segundas matrices ponderan el valor central para evitar una excesiva pérdida de detalle.

También se ha aplicado con bastante rendimiento otro tipo de filtraje, basado sobre la mediana en lugar de la media. El filtro mediano, se basa en sustituir el ND del píxel central por la mediana de los ND correspondientes a los píxeles vecinos. Su interés se corresponde con el propio de la mediana como medida de tendencia central: es menos sensible a los valores extremos y entraña una menor modificación de los datos que la media aritmética. En el contexto del procesamiento digital de imágenes, se ha empleado para eliminar valores anómalos aislados, fruto de ruidos aleatorios en la adquisición de los datos. Preserva mejor los contornos que el filtro promedio, pero demanda un mayor volumen de cálculo, lo que dificulta su aplicación cuando los recursos informáticos son escasos.

3.5.3.3 Filtros pasa altas

Este tipo de filtros pretende aislar los componentes de alta frecuencia en una imagen. En términos espaciales, esto supone remarcar digitalmente los contrastes espaciales entre píxeles vecinos, enfatizando los rasgos lineales presentes en la imagen, como carreteras, parcelas o accidentes geológicos. En definitiva, se intenta reforzar los contornos entre áreas homogéneas, evidenciando cualquier discontinuidad.

Varios métodos pueden conseguir este objetivo. El método más sencillo consiste en restar de la imagen original la obtenida por un filtro de pasa bajas. La razón es bastante obvia: si lo que se pretende es aislar los componentes de alta frecuencia (alta variabilidad), basta restar de la imagen original aquellos correspondientes a la baja frecuencia, con lo que sólo quedarían los requeridos, que se añadirían a la imagen original. En suma:

$$ND'_{i,j} = ND_{i,j} + (ND_{i,j} - ND^L_{i,j}) \quad [3.16]$$

donde ND' corresponde al ND de salida, ND al original, y ND^L al resultado de un filtro de paso bajas.

Más común, sin embargo, es emplear matrices de filtraje, similares a las anteriormente analizadas. En este caso, los CF se disponen de tal modo que se refuerza el contraste entre el píxel central y los vecinos. Dos matrices frecuentemente utilizadas son:

$$(4) \begin{matrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{matrix} \qquad (5) \begin{matrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{matrix}$$

ambas se derivan del análisis de gradientes de cambio en la imagen.

Este tipo de matrices de filtraje o mascarar, permiten subrayar cualquier rasgo fronterizo en la imagen, por lo cual se denominan comúnmente filtros detectores de bordes, y la técnica en general, realce de bordes.

Esta técnica puede emplearse para construir filtros direccionales, con el propósito de reforzar aquellas líneas que sigan determinadas orientaciones. Basta disponer adecuadamente los CF, distribuyéndolos en sectores de la matriz. Algunos ejemplos de matrices de filtraje para conseguir este análisis direccional son:

NORTE	SUR	ESTE	OESTE
1 1 1	-1 -1 -1	-1 1 1	1 1 -1
(6) 1 -2 1	(7) 1 -2 1	(8) -1 -2 1	(9) 1 -2 -1
-1 -1 -1	1 1 1	-1 1 1	1 1 -1

NOROESTE	SURESTE	SUROESTE	NOROESTE
1 1 1	-1 -1 1	1 -1 -1	1 1 1
(10) -1 -2 1	(11) -1 -2 1	(12) 1 -2 -1	(13) 1 -2 -1
-1 -1 1	1 1 1	1 1 1	1 -1 -1

A continuación se presentan cuatro matrices de filtraje de 3 x 3 adicionales, las cuales pueden ser usadas para detectar bordes en las imágenes:

VERTICAL	HORIZONTAL	DIAGONAL	DIAGONAL
-1 0 1	-1 -1 -1	1 1 1	1 1 0
(14) -1 0 1	(15) 0 0 0	(16) -1 0 1	(17) 1 0 -1
-1 0 1	1 1 1	-1 -1 0	1 -1 -1

Los filtros del (6) al (17), se pueden tomar como una aproximación a la primera derivada o el gradiente entre los dos píxeles adyacentes. El filtro (5), en cambio, es del tipo

Laplaciano, el cual representa la segunda derivada (lo opuesto al gradiente, el cual representa la primera derivada) y permanecen invariantes a la rotación, lo cual significa que son insensibles a la dirección en la cual las discontinuidades (puntos, líneas y bordes) se mueven (Jensen, 1996). Estos son recomendados para el realce de rasgos lineales en la ciudad. El proceso de aplicar este filtro sobre alguna imagen urbana, implica una mayor nitidez para los abundantes rasgos lineales de la imagen: carreteras y líneas de ferrocarril, aeropuertos, caminos, etc. Precisamente esta abundancia de líneas explica que las imágenes resultantes aparezcan un tanto confusas, ya que el filtro realiza los numerosos trazos limitrofes de la zona, perdiendo claridad las áreas internas a esos límites. En algunos casos, las máscaras de filtraje Laplaciano permiten subrayar cualquier rasgo fronterizo de la imagen, independientemente de su orientación.

A continuación se muestran otros ejemplos de filtros Laplacianos:

$$\begin{array}{ccc}
 \begin{array}{ccc} 0 & -1 & 0 \\ (18) & -1 & 4 & -1 \\ & 0 & -1 & 0 \end{array} &
 \begin{array}{ccc} & -1 & -1 & -1 \\ (19) & -1 & 8 & -1 \\ & -1 & -1 & -1 \end{array} &
 \begin{array}{ccc} & & 1 & -2 & 1 \\ (20) & -2 & 4 & -2 \\ & & 1 & -2 & 1 \end{array}
 \end{array}$$

Es recomendable, también, el empleo de filtros no lineales para reforzar fronteras o rasgos de interés en la imagen. Uno de los más empleados, en este sentido, es el denominado detector de bordes de Sobel, relaciona la variación entre filas y columnas de la matriz de filtraje. En una ventana de 3 x3 píxeles, el ND del píxel central se calcula de la forma siguiente:

$$ND'_{i,j} = \sqrt{X^2 + Y^2} \quad [3.17]$$

donde:

$$X = (ND_{i-1,j+1} + 2ND_{i,j+1} + ND_{i+1,j+1}) - (ND_{i-1,j-1} + 2ND_{i,j-1} + ND_{i+1,j-1})$$

y

$$Y = (ND_{i-1,j} + 2ND_{i,j} + ND_{i+1,j}) - (ND_{i-1,j+1} + 2ND_{i,j+1} + ND_{i+1,j+1})$$

El operador Sobel puede ser calculado con la aplicación simultánea de las siguientes matrices o kernel a través de la imagen:

$$\begin{array}{ccc}
 \begin{array}{ccc} -1 & 0 & 1 \\ X = & -2 & 0 & 2 \\ & -1 & 0 & 1 \end{array} &
 \begin{array}{ccc} & & 1 & 2 & 1 \\ Y = & 0 & 0 & 0 \\ & -1 & -2 & -1 \end{array}
 \end{array}$$

Este procedimiento detecta bordes horizontales, verticales y diagonales. Otra aplicación interesante de los filtros Sobel, es la creación de *mapas de bordes*. Estos se logran al crear una nueva imagen, en la cual cada píxel tomará un cierto nivel de brillantez sólo si el píxel de la imagen sometida a un filtraje Sobel, sobrepasa un umbral determinado por el usuario. El objetivo será indicar si se trata o no de un píxel que se encuentra en un borde. Estos mapas de bordes aparecen frecuentemente como líneas blancas sobre un fondo negro o viceversa.

3.6 Transformaciones multispectrales de la imagen

Las transformaciones multispectrales son las operaciones dirigidas a crear bandas artificiales, a partir de combinaciones entre las originales, con objeto de mejorar la discriminación de algunos aspectos temáticos dentro de la imagen. Dicho brevemente, son transformaciones dirigidas hacia la clasificación temática. Obviamente, tales operaciones no proporcionan información nueva que no estuviera ya incluida en los datos originales. Permiten, no obstante, mejorar la disposición de los datos, de forma que determinados fenómenos de interés sean más evidentes.

La mayor parte de las transformaciones empleadas en percepción remota son lineales. En otras palabras, esas nuevas bandas se crean por combinación lineal de las originales: sumas ponderadas, multiplicaciones o divisiones, son las más habituales. Para acotar este comentario, en este trabajo se presentará el análisis de componentes principales (PCA), el cual será de utilidad para el desarrollo posterior de este.

3.6.1 Análisis de componentes principales (PCA)

El análisis de componentes principales (PCA) es una técnica bastante empleada en ciencias sociales y naturales. Su objetivo es resumir un grupo amplio de variables en un nuevo conjunto, más pequeño, sin perder una parte significativa de la información original.

El origen de esta técnica parece arrancar del cambio de la psicometría: al analizar una serie de pruebas de inteligencia, se intuía la presencia de una serie de factores, subyacentes a las variables medidas, que podrían explicar gran parte de la variación común en determinados grupos de variables. Por ejemplo, se comprobó que las puntuaciones obtenidas en física y matemáticas tendían a estar bastante relacionadas, así como las obtenidas por otros alumnos en historia y literatura. Esto hacía pensar en la existencia de otras variables más complejas, como la habilidad para el cálculo o la capacidad de abstracción, que permitirían resumir la información contenida en un mayor número de variables. Esos factores podrían cuantificarse a partir de las variables originales, estudiando sus relaciones comunes tal y como se miden en la matriz de varianza-covarianza. Los factores o componentes principales vendrían, por tanto, a ser como variables-síntesis de las medidas iniciales: un menor número de dimensiones, preservando lo más sustancioso de la información original.

Esta capacidad de síntesis ha sido la base de la aplicación del PCA en percepción remota. La adquisición de imágenes sobre bandas adyacentes del espectro, implica con frecuencia detectar información redundante, puesto que los tipos de cubierta tienden a presentar un comportamiento similar en regiones próximas del espectro. Por ello, las medidas realizadas en una banda pueden presentar una importante correlación con las deducidas de otra, haciendo que una o varias de ellas sean prácticamente irrelevantes. En este contexto, el PCA permite sintetizar las bandas originales, creando unas nuevas bandas -los componentes principales de la imagen-, que contengan la mayor parte de la información original.

Por otra parte, y desde el punto de vista meramente estadístico, el PCA facilita una primera interpretación sobre los ejes de variabilidad de la imagen, al identificar aquellos rasgos que se recogen en la mayor parte de las bandas y los que son específicos a algún grupo de ellas. Una mejor distribución de los datos, frente a esos ejes de variabilidad, puede facilitar una identificación más atinada de las distintas cubiertas.

El sentido y la fuerza de la correlación lineal entre dos variables pueden representarse gráficamente mediante un eje divariado. En este contexto, la nube de puntos indica la localización de los valores de brillantéz (ND) en las dos bandas consideradas. La elipse que limita estos puntos, expresa gráficamente la fuerza de la correlación entre las dos bandas, tanto mayor cuanto más se aproxime a una recta, o -dicho de otro modo- cuanto mayor sea el contraste entre los dos ejes de esa elipse. En la figura 3.19 aparece una correlación positiva con dos ejes de variación: el primero en el sentido de la correlación (*A*), y el segundo, perpendicular a *A*, en el sentido de los residuales (*B*). Gráficamente se intuye, que una rotación de los *X_i* y *Y_j* hacia las direcciones *A*, *B*, mejorará la disposición original de los datos, y probablemente también la separación entre los grupos de ND homogéneos en la imagen. Esa rotación se obtiene, simplemente, aplicando una función del tipo:

$$CP_i = a_{11}ND_i + a_{12}ND_j$$

donde *CP_i* indica el valor correspondiente al primer componente principal, obtenido a partir de los ND originales de las bandas *i* y *j*, tras aplicarles unos determinados coeficientes *a₁₁* y *a₁₂*. En forma similar, podría expresarse el desarrollo del segundo componente, ya que existen tantos CP como bandas originales. No obstante, en caso de cinco o seis bandas, sólo los primeros componentes son realmente significativos, por cuanto en el proceso de extracción de los distintos CP se va maximizando, sucesivamente, la variación original acufada por cada uno.

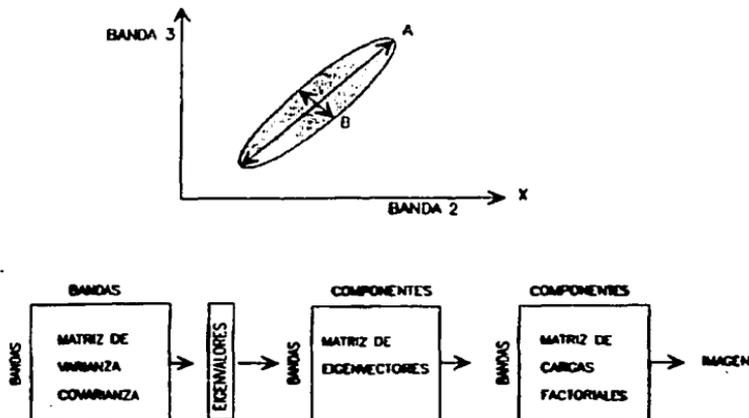


Fig. 3.19 Proceso aplicado a la obtención de Componentes Principales.

Desde el punto de vista geométrico, y como puede observarse en la figura 3.19, este nuevo eje sólo supone una rotación de los originales. En ocasiones, puede ser de gran interés acompañar la rotación con una traslación de los ejes, situando el origen de coordenadas en los valores mínimos de las dos bandas implicadas en el proceso. Basta, para ello, añadir dos constantes a_{01} y a_{02} a la ecuación arriba señalada.

Esta misma filosofía se aplica al trabajo con un mayor número de dimensiones. Lógicamente, la deducción de los nuevos ejes para 4 o 7 variables no puede realizarse gráficamente, sino que es preciso aplicar una transformación matemática compleja, que encuentre los nuevos ejes de variación que contengan la mayor parte de la información original de la imagen (El desarrollo detallado de esta técnica, puede consultarse en (Jensen, 1996) y (Richards, 1993), o bien en libros de estadística).

En términos sencillos, el proceso puede resumirse en los siguientes pasos. A partir de la matriz de varianza-covarianza, se extraen los eigenvalores para cada uno de los componentes (λ_p). Los eigenvalores expresan la longitud de cada uno de los nuevos componentes, y, en última instancia, la proporción de información original que retienen. Como antes se indicó, el PCA deduce tantos componentes como bandas originales, si bien el eigenvalor va disminuyendo progresivamente, del primero a los últimos, pues se pretende maximizar sucesivamente la varianza extraída en el análisis. La varianza original explicada por cada componente se calcula como la proporción de su eigenvalor frente a la suma de todos los eigenvalores:

TESIS CON
FALLA DE ORIGEN

$$V_p = \frac{\lambda_p \times 100}{\sum_{p=1}^m \lambda_p} \quad [3.18]$$

siendo m el número total de componentes.

Junto a la longitud de cada eje, resulta también de gran interés conocer su dirección. En definitiva, para poder interpretar el sentido de las nuevas variables, se requiere conocer su relación con las originales. De igual forma, para calcular las ecuaciones que servirán para obtener las nuevas imágenes, se precisa contar con los coeficientes de la transformación. Ambos aspectos, pueden abordarse a partir de los eigenvectores. El eigenvector indica la ponderación que debe aplicarse a cada una de las bandas originales para obtener el nuevo CP. Dicho brevemente, equivale a los coeficientes de regresión en una transformación lineal estándar, siendo las bandas de la imagen las variables independientes, y los CP las dependientes.

A partir de los eigenvectores, puede calcularse la matriz de correlación entre CP y bandas de la imagen, lo que nos permite conocer el sentido espectral de estos componentes. Basta aplicar:

$$r_{p,k} = \frac{a_{p,k} \sqrt{\lambda_p}}{s_k} \quad [3.19]$$

donde $r_{p,k}$ indica el coeficiente de correlación entre el componente p y la banda k ; $a_{p,k}$, el eigenvector del componente p en la banda k ; λ_p , el eigenvalor del componente p , y s_k , la desviación estándar de la banda k .

El último paso es obtener una imagen de los componentes principales. Para ello, basta acudir a la matriz de eigenvectores ($a_{p,k}$), donde se mide la relación lineal de cada CP y las bandas originales. Al igual que otras transformaciones lineales, el cálculo de las nuevas bandas, o CP, se realiza de la forma siguiente:

$$CP_{i,j,p} = \sum_{k=1}^n a_{p,k} \times ND_{i,j,k} \quad [3.20]$$

siendo n , el número de bandas; $CP_{i,j,p}$ el valor de la imagen del componente principal p para las coordenadas i, j ; $a_{p,k}$, los eigenvectores para dicho componente en cada una de las k bandas, y $ND_{i,j,k}$, el ND de esa misma banda para las mismas coordenadas.

Una vez obtenida la imagen de las CP, pueden éstas representarse en blanco y negro o color, obteniéndose una nueva visualización de la zona de estudio. Para ello, convendrá escalar los resultados en el rango que permite el equipo de visualización (0 a 255).

A continuación se presenta un ejemplo de una imagen de la ciudad de Madrid (Chuvieco, 1990), para ilustrar esta técnica de análisis. A partir de una muestra sistemática de 100 líneas y 90 columnas (1 de cada 9 píxeles), se obtuvo la matriz de varianza-covarianza para las siete bandas de la imagen (tabla 3.8).

Sobre esa matriz se calcularon los eigenvalores de la imagen, realizando una previa estandarización, con objeto de paliar el efecto de la distinta variabilidad entre bandas. Los eigenvalores (λ_p) extraídos fueron: 2160.31, 262.32, 149.34, 63.41, 25.67, 19.15 y 1.91. De acuerdo con la ecuación [3.18], la varianza original asociada con cada uno de estos componentes puede calcularse como: 80.54% para el primer componente, 9.78% para el segundo, 5.57% para el tercero, 2.36% para el cuarto, 0.96% para el quinto, 0.71% para el sexto y 0.071% para el séptimo. De acuerdo con estos porcentajes, se seleccionaron únicamente los tres primeros componentes, que retenían un total del 95.89% de la varianza original de la imagen.

Tabla 3.8 Matriz de varianza-covarianza de la imagen de Madrid.

	B1	B2	B3	B4	B5	B6	B7
B1	327.18						
B2	241.87	169.24					
B3	347.53	251.84	399.01				
B4	180.96	145.69	240.51	267.41			
B5	395.84	304.24	523.05	391.75	1019.08		
B6	41.68	33.93	68.29	23.86	152.27	95.66	
B7	289.14	203.65	317.56	171.60	520.23	76.82	359.53

El sentido espectral de estos componentes, se obtuvo a partir de la matriz de eigenvectores, en donde se evidencia la asociación entre cada componente y las bandas originales. Como puede analizarse en la tabla 3.9, el primer componente resultó un promedio ponderado de todas las bandas. Recoge, en consecuencia, una valoración de las características espectrales comunes a todas ellas. El segundo componente aparece con un significado más claro, pues presenta una importante asociación positiva con la banda 5, y negativas con las tres visibles. Esto indica una valoración, aunque negativa, de las concentraciones de humedad, a las que el infrarrojo medio resulta especialmente sensible. Por último, el tercer componente, ofrece un claro perfil de las cubiertas vegetales, con una importante asociación positiva en la banda 4 (infrarrojo cercano) y negativa en el infrarrojo medio y espectro visible.

Tabla 3.9 Matriz de eigenvectores de la imagen de Madrid.

	I	II	III
B1	0.348	-0.621	-0.067
B2	0.253	-0.327	-0.043
B3	0.407	-0.303	-0.093
B4	0.275	-0.109	0.793
B5	0.652	0.602	-0.056
B6	0.090	0.198	-0.374
B7	0.375	-0.047	-0.461

4. CLASIFICACIÓN DE IMÁGENES MULTIESPECTRALES

Para la mayor parte de las aplicaciones de la Percepción Remota, la clasificación supone la fase culminante del tratamiento digital de imágenes. Hacia ella se orientan, casi siempre, las operaciones hasta aquí estudiadas. Este papel protagonista viene dado por la misma naturaleza de la percepción remota. Los niveles de brillantez (ND) adquiridos por el sensor no tienen sentido en sí mismos, sino en cuanto son interpretables; esto es, convertibles a categorías que supongan un mejor conocimiento del territorio. Esta interpretación puede hacerse visualmente, sobre reproducciones fotográficas de las imágenes, o digitalmente, empleando la potencia y rapidez de cálculo que proporciona la computadora. Como fruto de la clasificación digital se obtiene uná cartografía e inventario de las categorías objeto de estudio. La información multispectral se condensa en un documento cartográfico y en unas tablas estadísticas, que definen la localización y ofrecen el inventario superficial de las categorías de interés.

Cabe también abordar un proyecto basado exclusivamente sobre los ND de la imagen. En este caso, el objetivo sería establecer una relación cuantitativa entre determinados parámetros físicos -como son: contenido de biomasa, estrés de la vegetación, humedad del suelo, etc.- y los ND que adquirió el sensor. Se trata ésta de una línea de trabajo todavía poco desarrollada, debido a la gran complejidad para modelar los diversos factores que intervienen en la adquisición de la imagen: tipo de cubierta, densidad, situación, grado de mezcla con otras especies, condiciones atmosféricas, geometría de adquisición, etc. Estos factores dificultan notablemente el establecimiento de modelos cuantitativos, por cuanto resulta muy complejo convertir en parámetros físicos los ND finalmente incluidos en la imagen. En este sentido, no cabe hablar de una percepción remota en donde las medidas del sensor puedan usarse en términos absolutos.

La alternativa pasa por considerar los ND de la imagen como medidas relativas. Quiere esto decir que, aunque no puedan traducirse propiamente a magnitudes físicas, sí indican una valoración ordinal entre los píxeles que componen una imagen determinada. En otras palabras, si bien no puede conocerse con rigor el valor de reflectancia que corresponde a cada ND, sí podemos afirmar que cuanto mayor sea su ND, mayor será la reflectancia de la parcela del terreno a la que corresponde ese píxel. Evidentemente, estas comparaciones pueden realizarse para cada banda, y no entre ellas, ya que los coeficientes de calibración del sensor y las influencias atmosféricas no son equiparables entre bandas. En términos similares cabe expresarse en lo que se refiere a las comparaciones entre imágenes de la misma zona, pero adquiridas en distinta fecha, o para imágenes de distintas zonas, por cuanto estará influida por peculiares condiciones atmosféricas y medio ambientales.

En consecuencia, la clasificación digital no busca una definición absoluta de cada cubierta, que pudiera ser aplicable a cualquier imagen, sino más bien una caracterización particular, válida para una determinada imagen y un territorio concreto. Con este planteamiento, no resulta preciso conocer detalladamente las condiciones de adquisición; basta identificar en la imagen las cubiertas de interés, sin pretender que esa identificación sea extrapolable a otras situaciones. En resumen, no se trata de establecer un modelo entre

medidas digitales y parámetros físicos, sino entre medidas digitales, en un momento dado, y tipos de cubierta. En este sentido, la clasificación supone un enfoque más cualitativo, si bien, por tratarse de un proceso numérico, incorpora un aparato estadístico ciertamente importante.

La clasificación digital se dirige a obtener una nueva imagen, en la cual cada uno de los píxeles originales venga definido por un ND, que es el identificador de la clase en donde se haya incluido. Estas clases pueden describir distintos tipos de cubierta, o bien intervalos de una misma categoría de interés. Por ejemplo, una clasificación de especies vegetales estaría dentro del primer grupo, mientras un intento de señalar niveles de afectación en un incendio forestal o de humedad en una inundación, estaría en el segundo.

Sea uno u otro el propósito del proyecto, la clasificación digital sigue cauces análogos a los que se emplean en foto-interpretación. En esta técnica, en primer lugar el intérprete identifica cada cubierta, de acuerdo a una serie de criterios: tono, textura, forma, disposición, etc., tal y como aparecen en unos fotogramas tipo. Posteriormente, delimita sobre el resto de las fotografías las zonas que se corresponden con ese patrón previamente definido. En otras palabras, asigna a cada categoría unas superficies determinadas, en función de la semejanza de éstas con el patrón tipo identificado previamente. Por último, verifica sobre el terreno la interpretación realizada.

Este es también el esquema de la clasificación digital. Basta traducir los criterios analógicos por digitales, por cuanto se realiza sobre los ND presentes en la imagen. De esta forma, pueden distinguirse las siguientes fases:

- i. Definición digital de las categorías (fase de entrenamiento).
- ii. Distribución de los píxeles de la imagen en una de esas categorías (fase de asignación).
- iii. Comprobación y verificación de resultados.

La clasificación digital se inicia definiendo cada una de las categorías que pretenden discriminarse. Por cuanto se trata de una clasificación numérica, esta definición también debe ser numérica; esto es, se trata de obtener el ND, o mejor aún el rango de ND, que identifica a cada categoría, para todas las bandas que intervienen en la clasificación.

Diversos factores introducen una cierta dispersión en torno al comportamiento espectral medio de cada cubierta. Esto implica que las distintas categorías no se definen por un solo ND, sino por una serie de ND, más o menos próximos entre sí. En términos de su clasificación digital, esto supone que existe una cierta dispersión en torno al ND que define cada categoría, más o menos significativa según las clases que se consideren y la propia complejidad del paisaje donde éstas se asienten. Por ello, la fase de entrenamiento resulta ciertamente compleja: se trata de definir con rigor cada una de las categorías que pretenden discriminarse, teniendo en cuenta su propia variabilidad en la zona de estudio.

Este objetivo se logra seleccionando una muestra de píxeles de la imagen, que represente, adecuadamente, a las categorías de interés. A partir de esos píxeles pueden calcularse los ND medios y la variabilidad numérica de cada categoría, en todas las bandas que intervienen en la clasificación. Al igual que en cualquier otro muestreo, el objetivo de esta fase es obtener los resultados más precisos con el mínimo coste. En otras palabras, identificar

debidamente las distintas categorías, reduciendo a lo imprescindible los trabajos de campo. Al igual que en otras aplicaciones del muestreo, las estimaciones posteriores se basan sobre la muestra seleccionada, por lo que una selección incorrecta de ésta conducirá inexorablemente a resultados pobres en la clasificación posterior. Los resultados de la clasificación, están mucho más influidos por la definición previa de las categorías, que por el criterio con el que éstas son posteriormente discriminadas. En definitiva, la fase de entrenamiento constituye la columna vertebral de la clasificación numérica.

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado. El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado procede a una búsqueda automática de grupos de valores homogéneos dentro de la imagen. Queda al analista, en este caso, la labor de encontrar correspondencias entre esos grupos y sus categorías de interés.

Para iluminar el sentido de ambos métodos, en el contexto de la clasificación digital, puede ser conveniente introducir una pequeña reflexión sobre el tipo de categorías que pueden intervenir en una clasificación temática. Suelen distinguirse, a este respecto, dos tipos de clases: informacionales y espectrales (Chuvieco, 1990). Las primeras son las que constituyen la leyenda de trabajo que pretende deducir el intérprete (tipos de ocupación del suelo, por ejemplo). Las segundas, corresponden a los grupos de valores espectrales homogéneos dentro de la imagen, en función de ofrecer una reflectancia similar, para las bandas consideradas y en la fecha concreta de la imagen. Las categorías informacionales se establecen por el usuario, mientras las espectrales se deducen de los ND presentes en la imagen.

Idealmente habría de producirse una correspondencia biunívoca entre las dos (Fig. 4.1); esto es, que a cada clase de cobertura le corresponda un único grupo espectral, y que cada grupo espectral corresponda a una sola clase temática. Desgraciadamente este caso es muy poco frecuente, produciéndose, normalmente, alguna de las siguientes situaciones:

- i. Que una categoría de cubierta esté expresada en varias clases espectrales. Por ejemplo, el caso del agua en distintos tipos, de acuerdo a su profundidad o turbidez. En estos casos, basta perfeccionar el muestreo, de tal forma que se defina correctamente la dispersión espectral de cada clase. Si los grupos espectrales a que corresponden son muy variados, puede dividirse una categoría informacional en varias subclases, para luego fundirlas -tras la clasificación- en una sola especie temática. Esto evita contar con clases muy heterogéneas espectralmente, y, por lo tanto, fácilmente sujetas a confusión con otras vecinas.
- ii. Otro caso sería que dos o más categorías informacionales compartan una sola clase espectral. Esto implicaría que algunas categorías de la leyenda no son discriminables, a partir de la imagen con que se cuenta, sin grave peligro de confusión. En este caso, la opción más razonable sería optar por una clave más general, evitando descender a un nivel de desagregación no abordable a partir de esos datos. Por ejemplo, podría optarse por una clase denominada urbana, en lugar de distinguir distintas densidades de edificación. En caso de que las confusiones se den entre categorías no asimilables a una clave más genérica, habría que analizar una imagen perteneciente a otra fecha del

año en donde esa confusión sea evitable. Lógicamente, también pueden intentarse otros medios, como lo sería refinar el método de muestreo.

- iii. Por último, puede también ocurrir que varias clases informacionales compartan clases espectrales. En este caso convendría replantear la estrategia de trabajo, aunque soluciones parciales pueden estimarse a partir de los párrafos anteriores.

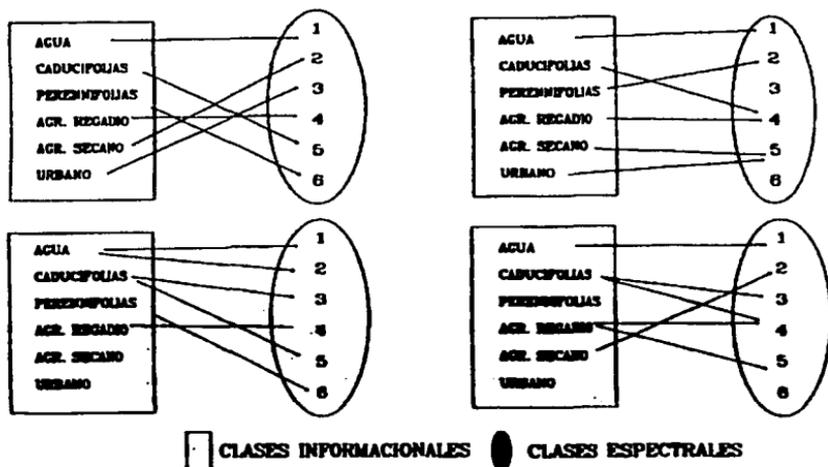


Fig. 4.1 Relaciones entre clases informacionales y espectrales.

A la luz de este comentario, parece claro que el método supervisado pretende definir clases informacionales, mientras el no supervisado tiende a identificar las clases espectrales presentes en la imagen. De los párrafos anteriores, también puede deducirse que ninguno de los dos métodos proporciona una solución inmediata a todos los problemas que entraña una clasificación digital. Por un lado, el método supervisado puede tacharse de subjetivo y artificial, pues puede "forzarse" a la computadora a discriminar categorías que no tengan un claro significado espectral. Por otro, el método no supervisado proporciona en ocasiones resultados de difícil interpretación, poco conectados con las necesidades del usuario final del producto.

TESIS CON
FALLA DE ORIGEN

4.1 Clasificación supervisada

El método supervisado parte de un cierto conocimiento de la zona de estudio, adquirido por experiencia previa o por trabajos de campo. Esta mayor familiaridad con la zona test, permite al intérprete delimitar sobre la imagen unas áreas piloto, que se consideran suficientemente representativas de las categorías que componen la leyenda. Estas áreas se denominan, en la bibliografía anglosajona, *training fields* (campos de entrenamiento). El término indica que tales áreas sirven para "entrenar" a la computadora en el reconocimiento de las distintas categorías. En otras palabras, a partir de ellas la computadora calcula los ND que definen cada una de las clases, para luego asignar el resto de los píxeles de la imagen a una de esas categorías, en función de sus ND.

La mayor parte de los sistemas que se usan para el procesamiento digital permiten localizar interactivamente los campos de entrenamiento. Con ayuda del *mouse*, el usuario introduce sobre la pantalla las zonas que definen cada una de estas áreas, asignándolas a una de las categorías definidas previamente en la leyenda. Los trabajos de campo y otros documentos auxiliares -como la fotografía aérea o la cartografía convencional- pueden ser de gran ayuda para una localización más precisa de estas áreas, teniendo en mente que debe tratarse de ejemplos suficientemente representativos y homogéneos de la clase que pretende definirse. Acabada la delimitación de un campo de entrenamiento, pueden seleccionarse otros para la misma categoría, o bien culminar con él la definición de esa clase. En general, resulta conveniente seleccionar varios campos por categoría, a fin de reflejar adecuadamente su variabilidad en la zona de estudio.

Finalizada la selección de las áreas de entrenamiento, la computadora calcula las estadísticas elementales de cada categoría: media, rango, desviación estándar, matriz de varianza-covarianza, etc., a partir de los ND de todos los píxeles incluidos en los campos de entrenamiento asignados a esa clase. Lógicamente, este cálculo se aplica a todas las bandas que intervendrán en la clasificación. En definitiva, se asume que las áreas de entrenamiento son fieles representantes de las distintas categorías, y que, por tanto, las medidas extraídas a partir de sus ND definen convenientemente a esas clases. De aquí que sea crucial la correcta selección de los campos de entrenamiento. De otra forma, la clasificación estaría viciada de partida, al pretender discriminar categorías con escaso significado espectral.

Un sencillo ejemplo puede servir para ilustrar el proceso de selección de los campos de entrenamiento. Se trata de una imagen en la que aparecen sólo tres cubiertas: viñedo, encinar y cereal. Una primera opción sería localizar un campo de entrenamiento por categoría (Fig. 4.2a), con suficiente detalle para evitar confusiones con otras cubiertas. A partir de polígonos trazados previamente, la computadora contabiliza los ND de todos los píxeles incluidos en cada campo, y obtiene la media y desviación estándar de las categorías que tratan de definir.

Ahora bien, la selección de áreas de entrenamiento sería incorrecta si alguna se sitúa en zonas de transición entre cubiertas (Fig. 4.2b). Al tratarse de un área heterogénea, sus medidas estadísticas serían un cierto promedio de los distintos componentes. Se trataría de una clase híbrida y, en consecuencia, susceptible de confusión con otras categorías.

TESIS CON
FALLA DE ORIGEN

El error contrario sería seleccionar únicamente áreas de entrenamiento en aquellos parajes donde la categoría sea muy homogénea, obviando la variación real que esa cubierta recoge en la imagen (Fig. 4.2c). Por ejemplo, si se pretende clasificar el encinar, conviene seleccionar campos donde el encinar aparece más denso, así como en aquellas zonas en donde cubre menos el suelo, o bien donde se asocia con el matorral. Esto no quiere decir que ambos tipos de encinar deban incluirse en la misma categoría en la clasificación, puesto que podría originarse una clase poco coherente. Parece más recomendable establecer dos o más categorías (con distintos tipos de densidad), para luego proceder tras la clasificación, a unirlos en una sola clase temática. De estas frases se deduce que el método supervisado requiere un previo conocimiento de las características del área de estudio, así como de las categorías que pretenden discriminarse.

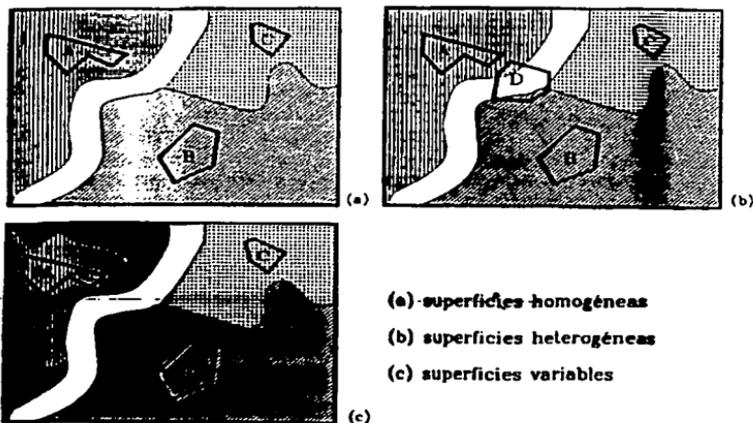


Fig. 4.2 Problemas en la selección de campos de entrenamiento.

Un último aspecto a considerar en la selección de los campos de entrenamiento, se refiere a los requisitos estadísticos que garantizan su grado de representatividad de las distintas categorías. Como antes se comentó, este proceso es una forma peculiar de muestreo espacial. Por ello, conviene tener en cuenta algunos criterios habituales en este tipo de técnicas para elegir el tamaño y la distribución más idónea de la muestra, así como para realizar estimaciones a partir de ella.

En cuanto al tamaño, se requiere seleccionar un mínimo de $m+1$ píxeles por categoría, siendo m el número de bandas que integran el análisis (Schowengerdt, 1983). Conviene, no obstante, superar con creces este límite mínimo. Diversos autores recomiendan seleccionar un número de píxeles comprendido entre $10m$ y $100m$ por categoría (Jensen, 1996). Este número

mínimo se relaciona estrechamente con el grado de asociación espacial entre píxeles. El muestreo convencional considera que las muestras seleccionadas son aleatorias e independientes. Esta suposición no es válida en este caso, por cuanto un campo de entrenamiento alberga a píxeles vecinos, afectados por el fenómeno de la auto-correlación espacial. En pocas palabras, esta asociación supone que la información original extraída de un número de píxeles contiguos, es menor que si fue extraída de otros dispersos. En suma, resulta más conveniente elegir varios campos de pequeño tamaño, que uno sólo de mayores dimensiones, ya que tenderá a infravalorarse la variabilidad de esa categoría.

Respecto a la distribución, conviene tener en cuenta las propias características de la imagen, intentando abarcar las variaciones espaciales que se presentan en cada categoría: su orientación, pendiente, densidad, vigor, contenido de humedad, tipo de suelo, etc. En este sentido, la variabilidad de una cubierta es directamente proporcional a la resolución del sensor (Cushnie, 1987). Dicho de otro modo, cuanto mayor sea el detalle espacial registrado en la imagen, mayor será también su sensibilidad para detectar las variaciones internas de una categoría, antes ocultas bajo un píxel de mayor tamaño. Por cuanto, a mayor heterogeneidad, mayor mezcla con clases similares -y, en última instancia, mayor riesgo de confusiones en la asignación posterior-, un incremento en la resolución espacial puede complicar la clasificación digital. Este hecho, que parece contradecir el sentido común (mayor resolución espacial, mayor precisión), ha sido puesto de manifiesto por diversos autores, que lo denominan "*scene noise*" ruido de la escena (Markham y Townshend, 1981). Se ha mostrado que el efecto es más importante en los tipos de cubierta más heterogéneos. Este es el caso de las áreas urbanas, en donde un píxel de mayor tamaño facilita adquirir una señal promedio de distintos componentes, mientras que cuanto más se reduzca el píxel, los efectos de frontera son más intensos.

Antes de abordar el proceso de clasificación propiamente dicho, conviene reflexionar sobre la discriminabilidad de las categorías seleccionadas. En otras palabras, es preciso evaluar la viabilidad de que esas categorías puedan clasificarse sin grave riesgo de error. Si se comprueba que dos o más son muy similares, habría una gran probabilidad de confusión entre ellas, por lo que resultaría aconsejable: (i) confirmar que las estadísticas de entrenamiento han sido correctamente deducidas; (ii) adoptar una leyenda más general, con nuevas categorías que supongan una mezcla de las que ofrecen mayor riesgo de confusión; (iii) recabar información auxiliar o imágenes de otras fechas.

Existen varios métodos -tanto gráficos como numéricos- para evaluar las estadísticas de entrenamiento. Entre los gráficos, el más elemental es un diagrama de respuesta espectral (firmas espectrales en las bandas de la imagen), donde figuran, en abscisas, las bandas que intervienen en el análisis, mientras en ordenadas los ND medios de cada categoría. Conviene no confundir esta gráfica con las curvas espectrales presentadas en el capítulo 2 del presente trabajo. Por un lado, aquí no se incluyen valores de reflectancia, sino ND. Por otro, la señal recogida por el sensor corresponde a la anchura completa de la banda, y no sólo a su centro. Con estas salvedades, esta gráfica resulta muy útil para proporcionar una primera valoración de las tendencias espectrales de cada categoría. Además, esta gráfica identifica aquellas bandas en las que se manifiesta un comportamiento peculiar respecto a clases vecinas. Las líneas paralelas y próximas indican un probable traslape entre categorías, mientras las

intersecciones entre líneas muestran las bandas donde es más probable separar a las categorías que representan.

Desafortunadamente la realidad es más compleja de lo que presenta esta gráfica, puesto que aquí sólo se refleja la tendencia media, sin considerar la variación propia de cada categoría, que es la principal responsable de las confusiones con otras clases vecinas. Una idea más clara de estos traslapes, puede obtenerse a partir de un gráfico de dispersión espectral. Se trata de un diagrama de barras que recoge, en cada banda y para cada categoría, el rango digital cubierto por la media más-menos una o dos desviaciones estándar.

Además de los procedimientos gráficos, existen algunos criterios cuantitativos que permiten evaluar numéricamente la posibilidad de discriminar las distintas categorías. El más sencillo es el denominado separabilidad estadística (Swain y Davis, 1978):

$$D_{norm A,B} = \frac{|\overline{ND}_A - \overline{ND}_B|}{s_A + s_B} \quad [4.1]$$

esto es, la distancia normalizada entre las clases A y B es fruto de establecer su diferencia absoluta entre medias, promediada por la suma de sus desviaciones estándar. Esta medida se aplica a cada par de bandas que intervienen en la clasificación. En las tablas construidas a partir de esta medida, entre mayor sea el valor que presentan, ésta indica una mayor separabilidad entre las categorías involucradas.

El análisis de las estadísticas de entrenamiento resulta muy conveniente para reflexionar sobre la conveniencia de la leyenda empleada, del tipo de información disponible, o del método emprendido para conseguir los resultados deseados. Una vez realizado este análisis, puede iniciarse la fase de clasificación propiamente dicha, en la que no deben producirse resultados muy distintos a los deducidos a partir de este estudio previo.

Una vez culminada la selección y estudio de las categorías que intervendrán en la clasificación, se inicia la siguiente fase, denominada de asignación, por cuanto se trata de adscribir cada uno de los píxeles de la imagen a una de las clases previamente seleccionadas. Esta asignación se realiza en función de sus ND, para cada una de las bandas que intervienen en el proceso. Fruto de esta fase será una nueva imagen, cuyos ND expresen las categorías en las cuales se ha incluido cada uno de los píxeles de la imagen original.

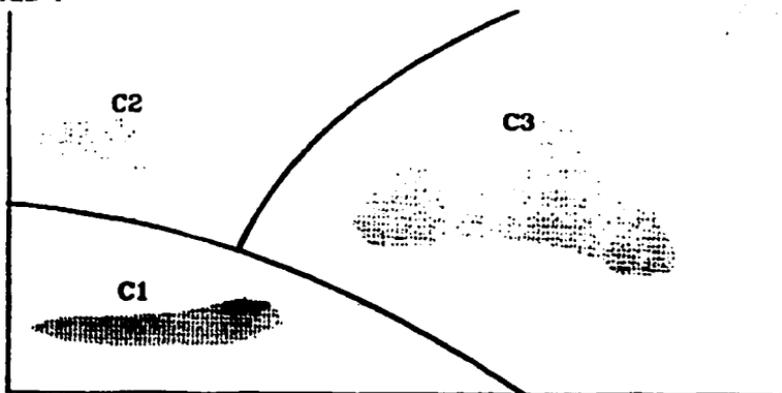
En las siguientes secciones se tratan los criterios más empleados para realizar este proceso en el contexto de las aplicaciones de la percepción remota. Desde un punto de vista estadístico, todos ellos definen un área de dominio, en torno al centro de cada categoría a discriminar, mediante un conjunto de funciones discriminantes. Estas ecuaciones pueden considerarse, por tanto, como las fronteras que definen cada categoría. El píxel será asignado a una clase i , si sus ND se encuentran dentro del área de dominio asignado a dicha clase (Fig. 4.3).

Los criterios más comunes para establecer estas fronteras estadísticas entre clases son:

- i. Mínima distancia, por este método el píxel es asignado a la clase más cercana.
- ii. Paralelepípedo, que permite señalar al usuario unos umbrales de dispersión asociados a cada clase.
- iii. Máxima verosimilitud, en donde el píxel se asigna a aquella clase con la que posee mayor probabilidad de pertenencia.

Frecuentemente se suelen agrupar en métodos no paramétricos, los dos primeros, y paramétricos, el último, en razón de si asumen o no que los ND en cada categoría se distribuyen normalmente. A continuación se describen, con más detalle, cada uno de estos criterios.

Banda Y



Banda X

Fig. 4.3 Funciones discriminantes para la asignación digital.

4.1.1 Clasificación por mínima distancia

El criterio más sencillo para asignar un píxel a una de las categorías consiste en incluirlo en la más cercana; esto es, en aquella que minimice la distancia entre ese píxel y el centroide de clase. Lógicamente, no se trata de una distancia geográfica, sino espectral, consecuencia de comparar los ND de cada píxel con los del centro de las distintas categorías, para todas las bandas que intervienen en el análisis.

TESIS CON
FALLA DE ORIGEN

Pueden considerarse varias formas de medir esa distancia espectral entre píxeles y clases. La más empleada, en este sentido, es la distancia euclidiana:

$$d_{x,A} = \sqrt{\sum_{k=1}^m (ND_{x,k} - \overline{ND}_{A,k})^2} \quad [4.2]$$

donde $d_{x,A}$ es la medida de la distancia entre el píxel x y la categoría A , que se calcula como la raíz cuadrada de la sumatoria de las diferencias entre el ND de ese píxel y el ND medio de la categoría A , para las m bandas que intervienen en la clasificación. Tras calcular esta medida para todas las categorías, puede obtenerse el valor $d_{x,A}$ más pequeño, asignando el píxel x a esa categoría (Fig. 4.4).

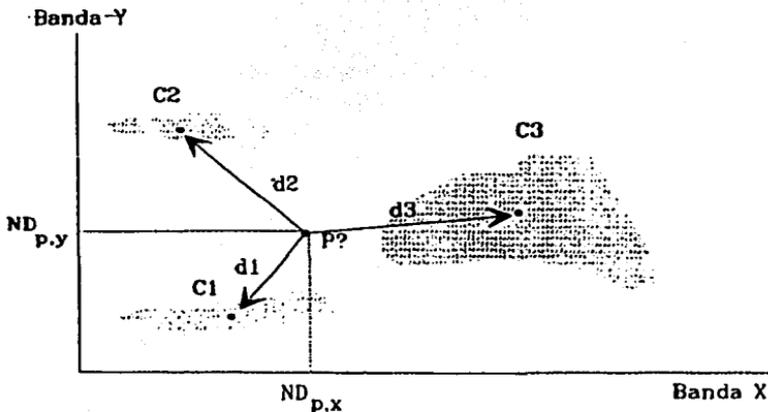


Fig. 4.4 Algoritmo de mínima distancia.

Este algoritmo es bastante sencillo y rápido de ejecutar, y puede ofrecer buenos resultados cuando no se observe un gran traslape entre categorías. Puesto que siempre existe una clase más cercana, no deja lugar a píxeles sin clasificar, incluso aunque éstos se alejen notablemente del centro de clase. Esto puede provocar errores de comisión importantes, sobre todo cuando no se incluye en la leyenda alguna categoría claramente presente en la imagen.

La distancia que calcula este algoritmo es lineal, sin considerar la propia dispersión de cada categoría o la correlación que exista entre las bandas. Tiende, por tanto, a delimitar grupos circulares de radio proporcional a la situación de cada categoría.

TESIS CON
FALLA DE ORIGEN

4.1.2 Clasificación por paralelepípedo

En este método, el usuario fija un área de dominio para cada categoría, teniendo en cuenta sus valores de centralidad y dispersión. Posteriormente, un píxel es asignado a dicha clase si sus ND están dentro de esa área de dominio, en todas las bandas consideradas. Esquemáticamente, el píxel x será asignado a la clase A si:

$$\overline{ND}_{A,k} - R_{A,k} < ND_{x,A} < \overline{ND}_{A,k} + R_{A,k} \quad [4.3]$$

para todo k , variando k de 1 hasta el número de bandas. $R_{A,k}$ indica el rango de dispersión concedido a cada categoría, y en cada banda.

En suma, el píxel x es asignado a la clase A si sus ND se encuentran a menos de una determinada distancia del centro de clase A . Esa distancia se fija por el intérprete, aunque suele identificarse con la desviación estándar o con un múltiplo suyo. Conviene considerar que cuanto mayor sea el umbral, mayor también el número de píxeles incluidos en esa categoría, pero también más grande el riesgo de confusiones con categorías vecinas. De igual forma, un valor pequeño garantiza mayor fiabilidad en las asignaciones, pero supone asimismo un mayor número de píxeles sin clasificar.

Este criterio de asignación tiende a delinear unos polígonos multidimensionales de lados paralelos, de ahí su nombre (Fig. 4.5), en torno al centro de cada categoría. Es un algoritmo muy rápido de ejecutar, puesto que no requiere cálculos aritméticos, sino sólo operaciones lógicas (tipo IF... THEN). Por esta rapidez, se ha utilizado con frecuencia como primer acercamiento a la variabilidad de las distintas categorías. Asimismo, se ha utilizado para lograr una primera estratificación de la imagen, aislando las categorías más singulares, para aplicar posteriormente un criterio de asignación sobre los píxeles más problemáticos.

Los principales problemas de este método parten de su misma concepción. El diseño de áreas de dominio implica, por un lado, que haya píxeles en zonas comunes a dos o más categorías, y, por otro, que algunos píxeles queden sin clasificar.

Respecto al primer problema, el traslape entre paralelepípedos supone que un píxel pueda asignarse a dos categorías. Si la computadora no cuenta con otro criterio, lo incluirá en la primera que cumpla los requisitos marcados en [4.3]. En consecuencia, algo tan intrascendente como el orden en el que se produce la asignación tiene una repercusión importante sobre los resultados. Algunos autores han propuesto modificar el criterio de asignación para estas áreas en conflicto, bien introduciendo la regla de mínima distancia (Wagner y Suits, 1983; Cosentino et al. 1981), bien ajustando interactivamente las fronteras entre clases (Lillesand y Kiefer, 1987).

TESIS CON
FALLA DE ORIGEN

Banda Y

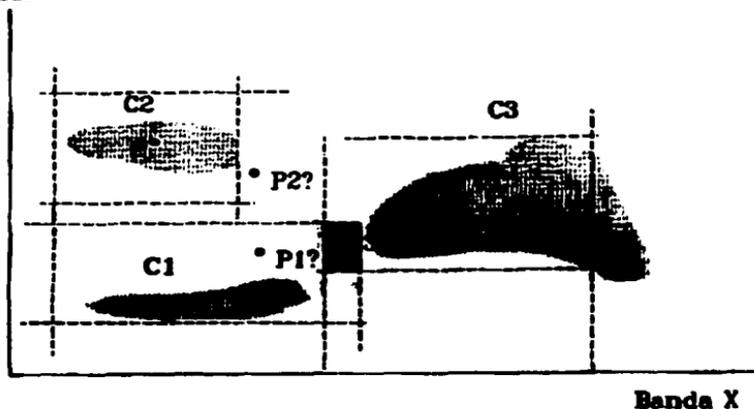


Fig. 4.5 Algoritmo de paralelepípedos.

Respecto a los píxeles sin clasificar, la solución pasa por ampliar paulatinamente el rango de dispersión, estableciendo un equilibrio entre los píxeles no clasificados y los traslapes entre clases vecinas. También conviene, en estos casos, repasar la definición espectral de las categorías, puesto que la presencia de píxeles sin asignación es indicio de clases espectrales mal definidas o no incluidas en la leyenda de trabajo.

4.1.3 Clasificación por máxima verosimilitud

Este método considera que los ND en el seno de cada clase se ajustan a una distribución normal. Esto nos permite describir esa categoría por una función de probabilidad, a partir de su vector de medias y matriz de varianzas-covarianza. En pocas palabras, esa función asemeja la distribución real de los ND en esa categoría, por lo que nos sirve para calcular la probabilidad de que un píxel (con un determinado ND) sea miembro de ella. El cálculo se realiza para todas las categorías que intervienen en la clasificación, asignando el píxel a aquella que maximice la función de probabilidad.

El clasificador de máxima verosimilitud es el más complejo y el que demanda mayor volumen de cálculo. Sin embargo, es el más empleado, por su robustez y por ajustarse con más rigor a la disposición original de los datos.

TESIS CON
FALLA DE ORIGEN

Para comprender mejor su funcionamiento, basta con poner un sencillo ejemplo ideado por Swain y Davis (1978). Supóngase que se cuenta con dos pares de dados, uno normal (caras numeradas de 1 a 6) y otro con un par de puntos adicionales en cada cara (numerados de 3 a 8). Conociendo el valor de una tirada, el problema sería estimar de cual de los dos pares de dados procede. Un criterio razonable de asignación sería calcular la probabilidad de que esa tirada se haya realizado con los dados normales o con los aumentados, asignándola a la más probable. Por ejemplo, si obtenemos una tirada de 7, la probabilidad de haber tirado con los dados normales es $6/36$ (6 casos favorables, frente a los 36 posibles, pues puede haberse obtenido un 7 por las siguientes combinaciones de dados: 1 y 6, 6 y 1, 2 y 5, 5 y 2, 2 y 3, 4 y 4, y 4 y 3). Para los dados aumentados, la probabilidad es menor, $2/36$ (sólo puede obtenerse un 7, en este caso, por combinación de 3 y 4, y 4 y 3), por lo que la tirada se asigna al par de dados normal.

El mismo criterio puede seguirse para cualquier otra puntuación. Basta construir las funciones de probabilidad asociadas con cada par de dados. Para el par normal, tendríamos una distribución centrada en el valor 7, con un mínimo de 2 y un máximo de 12. Para el par aumentado, el valor máximo se encuentra en 11, con un mínimo de 6 y un máximo de 16 (Fig. 4.6). A partir de esta gráfica, se observa que la probabilidad de haber usado los dados normales es mayor si obtenemos una tirada inferior a 8; es menor si la tirada superó 10 y es idéntica si la tirada fue 9. En definitiva, la frontera entre ambos tipos de dados se establece en la intersección entre sus respectivas funciones de probabilidad.

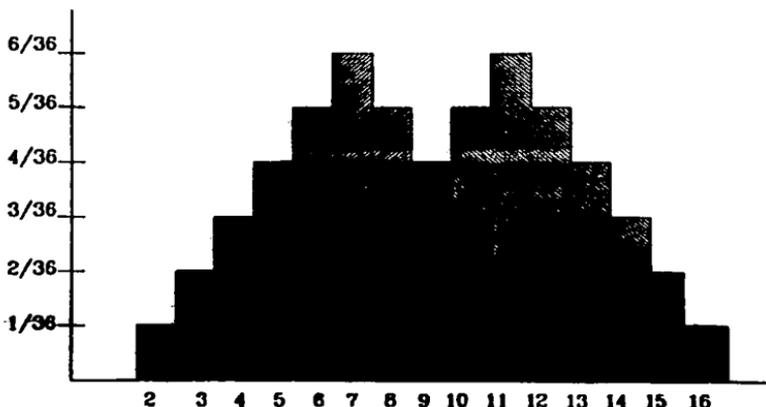


Fig. 4.6 Fundamentos del algoritmo de máxima probabilidad.

Esto no significa, obviamente, que no pueda producirse una tirada mayor a 9 con el par de datos normal, ni inferior a 9 con el aumentado. En otras palabras, la regla no es completamente certera, pero sí bastante razonable. Sólo es plenamente fiable para valores superiores a 12 o inferiores a 6, puesto que ahí no existe traslape entre categoría. En suma, si existe conflicto natural entre clases, no es posible separarlas con total fiabilidad. Los errores serán mayores, entre mayor sea el traslape entre las funciones de probabilidad.

El ejemplo puede aplicarse fácilmente al contexto de la clasificación digital. Los datos pueden sustituirse por las distintas categorías que quieren discriminarse, y las tiradas por los ND de los píxeles a clasificar. En el caso de los datos, podíamos estimar la probabilidad de pertenencia asociada con cada tirada. Aquí, es preciso estimar ese valor de probabilidad para cada categoría, a partir de las medidas realizadas sobre las áreas de entrenamiento. Para ello, se considera que los ND en cada categoría se distribuyen de acuerdo a la distribución normal, por lo que basta conocer la media y la desviación estándar de cada categoría, para calcular la probabilidad asociada con un determinado ND. Para el caso de trabajar con una sola banda podríamos calcular esa probabilidad de acuerdo con:

$$p(x/A) = \frac{1}{\sqrt{2\pi\sigma_A^2}} \exp\left\{-\frac{(ND_x - \overline{ND}_A)^2}{2\sigma_A^2}\right\} \quad [4.4]$$

Esto es, la probabilidad de que un píxel x , definido por un determinado ND_x , pertenezca a la clase A , puede calcularse a partir de la media (\overline{ND}_A) y la varianza (σ_A^2) de esa clase. Una vez determinada la probabilidad de pertenencia al resto de las categorías que intervienen en la clasificación, ese píxel será asignado a la clase A , sólo si:

$$p(x/A) \geq p(x/B) \quad [4.5]$$

para todo $A \neq B$, variando B desde 1 hasta n , siendo n el número de categorías.

Desde el punto de vista computacional, el cálculo resulta más sencillo cuando se transforma la fórmula anterior en una función lineal, mediante el empleo de logaritmos:

$$\ln p(x/A) = -0.5 \ln \sigma_A^2 - \left\{ \frac{(x - \overline{ND}_A)^2}{2\sigma_A^2} \right\} \quad [4.6]$$

La expresión puede simplificarse aún más si se elimina el primer término ($-0.5 \ln(2\pi)$), por cuanto nos interesa sólo un cálculo de la probabilidad relativo a las distintas clases, y ese valor es una constante para todas las categorías. Por la misma razón, no resulta necesario reconvertir a antilogaritmos el valor calculado, ya que si el logaritmo de la probabilidad es mayor en una categoría que en otra, también lo será su antilogaritmo. Por último, el segundo término ($1/5 \ln \sigma_A^2$) puede calcularse inicialmente, para cada categoría, quedando así reducido el cálculo, por píxel, a la última expresión.

Volviendo al ejemplo anterior, podría también ocurrir que se contara con dos pares de datos normales y sólo con uno aumentado. En este caso, no sólo se tendría que considerar el valor de la tirada para identificarla como perteneciente a uno u otro tipo de datos, sino

también la probabilidad *a priori* de que aparezca una tirada de cada par de dados, en función de su número. En muchas aplicaciones de la percepción remota también se produce este fenómeno. Algunas de las categorías cuentan con mayor extensión superficial y por lo tanto, presentan mayor probabilidad de albergar píxeles desconocidos. Al considerar la probabilidad *a priori* para cada categoría $p(A)$, se introduce un nuevo factor en el criterio de decisión enunciado en [4.5]. De esta forma, un píxel pertenecerá a la clase A si:

$$p(x/A) p(A) \geq p(x/B) p(B) \quad [4.7]$$

para todo $B \neq A$, donde $p(x/A)$ indica la probabilidad de que un píxel x con un ND determinado, pertenezca a la clase A y $p(A)$ la probabilidad *a priori* de que un píxel cualquiera se incluya en esa clase.

La figura 4.7 expresa gráficamente el efecto de introducir esta opción, denominada clasificación Bayesiana (Schowengerdt, 1983), en la cual el punto de corte entre las distribuciones de probabilidad, se desplaza a un lado u otro del original, en función del valor de la probabilidad *a priori*. Como la intersección entre curvas marca la frontera en el área asignada a cada categoría, este factor puede modificar significativamente los resultados.

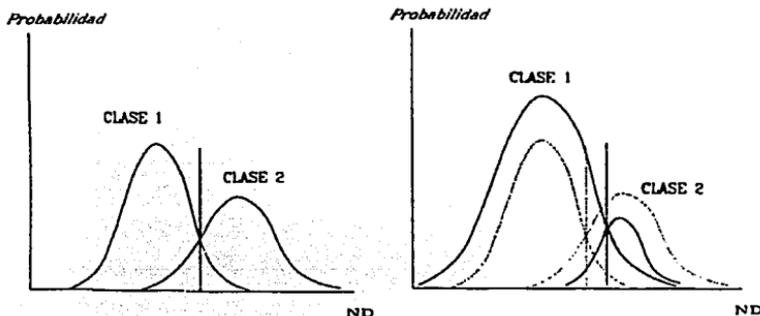


Fig. 4.7 Efecto de considerar la probabilidad *a priori*.

Con ser de gran interés, el empleo de este parámetro resulta bastante complejo, especialmente para establecer un criterio riguroso que permita estimar los valores de probabilidad *a priori* para cada clase. Un posible criterio sería conceder a cada categoría una probabilidad equivalente a la superficie que ocupa en la zona de estudio. Esto requiere, naturalmente, contar con un inventario previo, que raras veces está disponible. Indirectamente, sin embargo, puede calcularse la importancia superficial de cada clase mediante trabajos de campo, datos auxiliares o empleando los resultados de una clasificación previa. Por último, también puede optarse por obviar este criterio, simplemente otorgando la misma probabilidad *a priori* a todas las categorías.

Hasta el momento se ha analizado el criterio de máxima verosimilitud para el caso de una sola banda. Lo habitual será que se empleen varias bandas para la clasificación, por lo que resulta preciso extender a varias dimensiones lo hasta aquí comentado.

Para el caso de dos dimensiones (dos bandas), los límites de las categorías tienen una forma elipsoidal (Fig. 4.8). Cada una de estas elipses define un determinado nivel de probabilidad asociado a una categoría. Cuanto mayor sean las zonas de traslape entre categorías, tanto mayor es el riesgo de confusión mutua.

Con más de dos dimensiones, no es posible representar gráficamente este criterio de clasificación. Basta extender la fórmula de la probabilidad normal arriba apuntada:

$$p(x/A) = 2\pi^{-m/2} |V_A|^{-0.5} \exp\left[-0.5(X - M_A)^T V_A^{-1}(X - M_A)\right] \quad [4.8]$$

donde m indica el número de bandas, $|V_A|$ la determinante de la matriz de varianza-covarianza para la clase A ; X el vector de ND asociado con el píxel x ; M_A , el vector de ND medios de la categoría A , y los superíndices t y -1 , la traspuesta y la inversa de las matrices a las que afectan, respectivamente. Esta fórmula también puede simplificarse mediante el uso de logaritmos (Schowengerdt, 1983):

$$\ln p(x/A) = [-0.5 \ln |V_A|] - [0.5(X - M_A)^T V_A^{-1}(X - M_A)] \quad [4.9]$$

una vez suprimidos los términos constantes de la fórmula anterior.

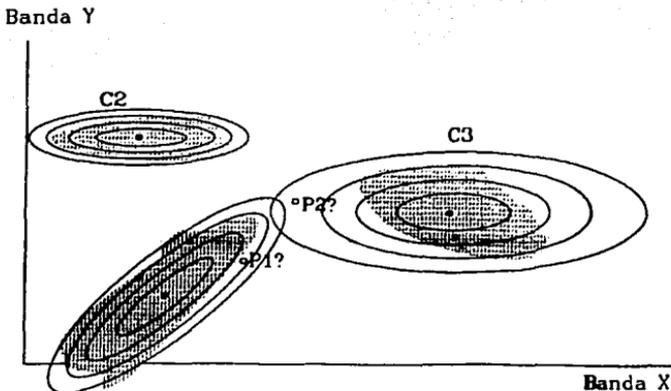


Fig. 4.8 Extensión a dos bandas del algoritmo de máxima verosimilitud.

Una vez que la computadora termina la asignación de los píxeles de la imagen, es posible establecer los umbrales de probabilidad para cada categoría, de tal forma que se rechacen aquellos píxeles con una probabilidad de pertenencia muy baja (Fig. 4.9). Este proceso, posterior a la clasificación propiamente dicha, pretende evitar aquellos píxeles con un grado de asociación muy bajo, reduciendo así los errores de comisión debidos a una mala definición espectral de algunas categorías.

Esto llevará consigo la aparición de píxeles no clasificados. Si su número es considerable, convendrá retornar a la fase de entrenamiento, con objeto de deducir nuevas categorías o perfeccionar la definición de las ya existentes.

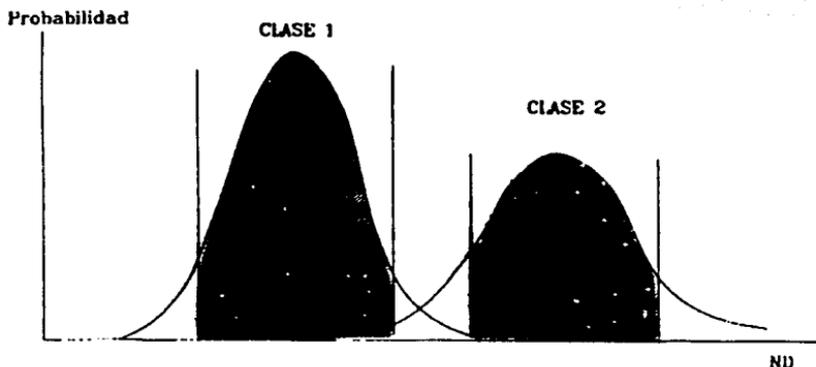


Fig. 4.9 Efecto de considerar la probabilidad a posteriori.

4.2 Clasificación no supervisada

Este método se orienta a definir las clases espectrales presentes en la imagen. No implica ningún conocimiento del área de estudio, por lo que la intervención humana se centra más en la interpretación, que en la consecución de los resultados.

En esta estrategia, se asume que los ND de la imagen forman una serie de agrupaciones o conglomerados (*clusters*), más o menos nítidos según los casos. Estos grupos equivaldrían a píxeles con un comportamiento espectral homogéneo y, por tanto, deberían definir clases temáticas de interés. Desgraciadamente estas categorías espectrales no siempre pueden

equipararse a las clases informacionales que el usuario pretende deducir, por lo que resta a éste "dar sentido" o interpretar, el significado temático de esas categorías espectrales.

El método para definir los agrupamientos espectrales se basa en un triple proceso:

- i. Selección de las variables que intervienen en el análisis.
- ii. Selección de un criterio para medir la similitud o distancia entre casos.
- iii. Selección de un criterio para agrupar los casos similares.

En el contexto de la Percepción Remota, las variables son las bandas espectrales seleccionadas para la clasificación, ya sean éstas originales o fruto de alguna transformación (como el PCA). Los casos son los píxeles que componen la imagen, cada uno de ellos definido por tantos ND como bandas intervienen en el análisis. En este espacio multivariado se trata de encontrar los grupos de píxeles con ND similares, para luego equiparlos con alguna de las clases informacionales de la leyenda.

El método para encontrar esos grupos homogéneos puede ilustrarse con el caso más simple, en el que se estuviese trabajando con dos bandas (infrarrojo cercano y rojo, por ejemplo). En un gráfico divariado aparecerían tantos puntos como píxeles, localizados de acuerdo a sus ND en cada banda (Fig. 4.10a). La gráfica evidencia la existencia de agrupaciones de píxeles, con ND similares en las dos bandas, que pueden identificar clases temáticas de interés. Por ejemplo, los puntos situados en el vértice inferior izquierdo corresponden a píxeles con ND bajos en las dos bandas; los situados en el sector opuesto son píxeles con altos valores en ambas bandas; mientras los correspondientes al extremo inferior derecho implican ND bajos en la banda Roja y altos en la Infrarrojo cercano. En estas regiones del espectro, podríamos identificar estos grupos como pertenecientes a agua, suelos desnudos o vegetación, respectivamente, aunque en esta fase sólo interesa conocer que se trata de grupos homogéneos.

La delimitación de cada grupo espectral se inicia señalando dos criterios: uno que mida la similitud entre píxeles, y otro que marque las condiciones del proceso de agrupamiento. En cuanto al primer aspecto, se han propuesto diversos criterios para medir la distancia entre píxeles. El más utilizado es el de la distancia euclidiana:

$$D_{a,b} = \sqrt{\sum_{k=1}^m (ND_{a,k} - ND_{b,k})^2} \quad [4.10]$$

donde $D_{a,b}$, indica la distancia entre dos píxeles cualquiera a y b ; $ND_{a,k}$ y $ND_{b,k}$, los niveles digitales o de brillantez de esos píxeles en la banda k , y m el número de bandas. Si bien hay otros criterios para medir la distancia, la distancia euclidiana resulta la más habitual en este tipo de aplicaciones.

TESIS CON
FALLA DE ORIGEN

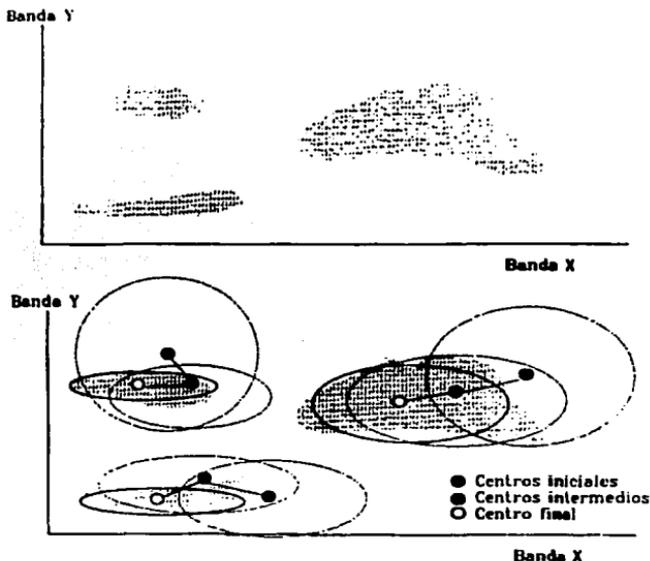


Fig. 4.10 Fundamentos del análisis no supervisado.

En cuanto al algoritmo de agrupamiento, las opciones también son muy numerosas. Uno de los más extendidos es el denominado ISODATA (Duda y Hart, 1973). En esencia, este algoritmo procede a partir de las siguientes fases (Fig. 4.10b):

- i. Se señalan una serie de centros de clase, de acuerdo al número y forma indicados por el usuario.
- ii. Se asignan todos los píxeles de la imagen al centro de clase más próximo.
- iii. Se calculan de nuevo los centros de clase, teniendo en cuenta los valores de todos los píxeles que se le hayan incorporado en la fase anterior.
- iv. Se vuelven a asignar todos los píxeles de la imagen al centro más cercano, el cual - debido al desplazamiento registrado en (iii) - no tiene por qué coincidir con la anterior asignación realizada en (ii).
- v. Vuelven a calcularse los centros de clase, teniendo en cuenta las nuevas incorporaciones, y se retorna a la fase (iv).

El proceso se repite iterativamente hasta que el centro de clase no se desplace significativamente, lo que indica un buen ajuste a los grupos presentes en la imagen. Antes de iniciar una nueva iteración, el algoritmo interroga algunos parámetros de control introducidos por el usuario: ¿se ha alcanzado el número máximo de grupos para interrumpir el agrupamiento?, ¿algún grupo tiene un número de píxeles inferior al mínimo señalado, en cuyo caso se suprime?, ¿algún grupo está a una distancia inferior a la mínima señalada entre grupos para realizar una fusión?, ¿algún grupo cuenta con una varianza superior a la máxima señalada para que éste sea dividido? Una vez solventadas estas cuestiones, se procede a comenzar un nuevo ciclo de procesos (*loop*), o bien se finaliza la clasificación si el desplazamiento entre grupos ha sido inferior al señalado por el usuario.

Desde el punto de vista estadístico, este algoritmo parece bastante adecuado para delimitar los grupos de valores homogéneos dentro de la imagen. Sin embargo, en ocasiones resulta artificioso señalar unos parámetros de control significativos, puesto que el usuario no conoce, de partida, el número de grupos espectrales presentes en la imagen, ni el valor idóneo de dispersión interna o de distancia entre grupos. De esta forma, el análisis no supervisado se convierte en un proceso interactivo, en donde el usuario establece unos valores arbitrarios que se van modificando a la vista de los resultados.

4.3 Clasificación por contexto

Como ya se ha visto, la computadora realiza la asignación píxeles-categorías sobre la base de los ND. Estas metodologías son comúnmente llamadas clasificaciones por píxel, pues para realizar la clasificación se toma en cuenta solamente las propiedades espectrales del píxel por sí solo, sin importar los valores de los píxeles vecinos. Sin embargo, en cualquier imagen real, los píxeles adyacentes están relacionados o correlacionados, esto debido a que los sensores adquieren porciones significativas de energía de los píxeles adyacentes y a que las cubiertas terrestres generalmente sobrepasan el tamaño que el píxel puede captar. En un área agrícola, por ejemplo, si un píxel en particular dentro de la imagen está representando trigo, es muy probable que sus vecinos también representen trigo. Este conocimiento de las relaciones del píxel con sus vecinos es una rica fuente de información que no se explota en los tradicionales métodos de clasificación. En esta sección se hará énfasis en algunas de las técnicas más comunes para tomar en cuenta el contexto de los píxeles, sobre todo en aquellas que son muy simples de aplicar y, en contraparte a su sencillez, aportan una gran mejoría en los resultados de la clasificación. Es importante mencionar, que este incremento en la exactitud de la clasificación se da, no solamente por la inclusión de la información espacial del píxel; sino también porque ayuda a mejorar los mapas temáticos eliminando errores de los datos fuente, o bien errores propios de la técnica de clasificación usada.

Los métodos de clasificación que toman en cuenta a los píxeles vecinos cuando se busca la inclusión del píxel en particular a una clase determinada, se dice que son sensitivos al contexto, o bien son llamados en general clasificadores por contexto. Estos intentan obtener un mapa temático que sea consistente tanto espectral como espacialmente.

TESIS CON
FALLA DE ORIGEN

Se pueden agrupar las técnicas de clasificación por contexto en dos bloques (Chuvieco, 1990):

- i. Por un lado, aquellas que tienen en cuenta el contexto espacial de cada píxel para realizar su asignación a una categoría. Se trata de intentos de refinar la clasificación de cada píxel sobre la base de lo que ocurre en píxeles vecinos. Las posibilidades aquí son muy variadas: considerar la probabilidad de pertenencia de los píxeles contiguos en el clasificador de máxima verosimilitud (Danjoy y Sadowski, 1978); incluir una banda textural en la clasificación (Strahler y Logan, 1978; Gordon y Philipson, 1986), o clasificar, en lugar de píxeles aislados, áreas espectrales homogéneas (Hoffer y Swain, 1980).
- ii. Por otra parte, se pueden considerar a aquellos trabajos que emplean el criterio de vecindad para refinar los resultados de la clasificación. En este sentido la contigüidad espacial se aplica como un filtro posterior a la fase de asignación, que tiene por objeto formar áreas temáticas más homogéneas prescindiendo de aquellos píxeles aislados que complican innecesariamente los resultados (Campbell, 1987; Thomas, 1980). Estas técnicas que se valen de un filtro para refinar la clasificación han mostrado ser muy efectivos y muy sencillos de implementar.

Dentro del primer grupo de clasificadores de contexto, se situaría el denominado ECHO (*Extraction and Classification of Homogeneous Objects*, Ketting y Landgrebe, 1975). Se pretende clasificar una imagen en áreas compuestas por píxeles de similares características, antes de que éstos sean asignados a categorías. Posteriormente, la clasificación se realiza sobre estas áreas, en lugar de sobre píxeles aislados. La delimitación de esas áreas homogéneas se basa en los criterios de similitud espectral y contigüidad. Tras localizar un pequeño grupo de píxeles con ND similares, el algoritmo va incorporando progresivamente píxeles vecinos, siempre que estén dentro de un criterio de homogeneidad señalado por el usuario (por ejemplo, a menos de una determinada distancia espectral). Cuando los píxeles vecinos no son suficientemente homogéneos se detecta una frontera o un área pequeña de distinta ocupación (isla). Estas zonas se clasifican posteriormente de acuerdo a los criterios tradicionales. El proceso de crecimiento de las áreas continúa hasta que topan con áreas muy contrastadas, con lo que el proceso se detiene. En este punto, la imagen aparecerá segmentada en áreas homogéneas, aunque éstas aún no se hayan asignado a ninguna categoría temática. Esta asignación se realiza calculando las estadísticas elementales de los píxeles incluidos en cada área, y aplicando sobre ellas uno de los criterios de asignación antes comentados. En ese punto, no serán asignados píxeles individuales sino las áreas completas, por lo que la posibilidad de error tiende a reducirse considerablemente.

La aplicación del segundo tipo de clasificadores de contexto, puede ser tomada como una "suavización de resultados" (Chuvieco, 1990), pues lo que hacen es mejorar la presentación final del mapa temático, pues resulta bastante frecuente que los resultados de una clasificación digital adolezcan de una excesiva fragmentación. En otras palabras, las diversas categorías se intercalan entre sí, en una compleja sucesión espacial. Manchas de color, más o menos homogéneas, se encuentran salpicadas por píxeles asignados a otras categorías, perdiéndose su unidad geográfica y dificultando la interpretación de los resultados. Este suceso se denomina coloquialmente, en la bibliografía anglosajona, "efecto de sal y pimienta" (*salt and pepper*), y se debe a una doble causa: (i) por un lado, a que la mayor parte de los

TESIS CON
FALLA DE ORIGEN

criterios de asignación no tienen en cuenta la pertenencia de píxeles vecinos; (ii) por otro, a la propia complejidad del paisaje, directamente relacionada con la aparición de píxeles de borde que son los principales responsables de la discontinuidad visible en el mapa.

Para solucionar este problema, se aplica una técnica de suavización de resultados, similar en la concepción, aunque no en la ejecución, a los filtros pasa bajas. Sobre la imagen clasificada no puede aplicarse un filtro convencional, puesto que cualquier promedio de píxeles vecinos introduciría cambios imprevisibles en la clasificación. En otras palabras, no se trata de una imagen de tono continuo, sino de una imagen categorizada, en donde no tiene sentido establecer análisis de gradientes. Por esta razón, se aplican sobre la imagen esquemas de filtraje originales, basados sobre medidas categóricas en lugar de promedios.

El objetivo último es reasignar aquellos píxeles aislados o poco significativos, facilitando una distribución espacial más nítida de las distintas categorías. Para ello, se procede a comparar la clase asignada a cada píxel con la que ofrecen los píxeles vecinos. Si esa clase es similar a los píxeles del entorno, se mantiene la asignación original; caso contrario, se modifica. Normalmente esta comparación se realiza a partir de una ventana móvil de 3×3 píxeles, si bien la técnica es independiente de su tamaño. Se distinguen habitualmente, a este respecto, dos tipos de filtro:

- i. Filtro modal, en el cual, el píxel situado en el centro de la matriz se asigna a la categoría más frecuente los píxeles vecinos, siempre que, lógicamente, no pertenezca ya a ella (Fig. 4.11).
- ii. Filtro de mayoría. El píxel situado en el centro de la matriz se asigna a la categoría que cuente con la mitad más uno de los píxeles vecinos. En caso de que ninguna categoría rebase ese valor, el píxel central mantiene su asignación original.

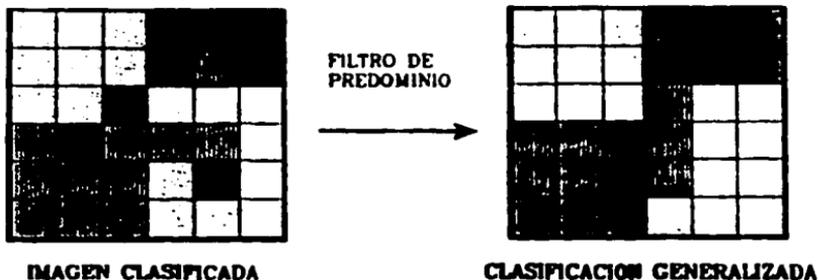


Fig. 4.11 Filtros para el suavizado de las clasificaciones.

La elección entre uno u otro método depende del tipo de paisaje analizado y del algoritmo que se haya empleado en la clasificación. Lógicamente, el primero ofrece una mayor generalización que el segundo, por lo que puede ser conveniente su empleo en caso de paisajes muy complejos y cuando la escala de trabajo sea media o pequeña.

Una variación a este tipo de técnicas es, el aplicar el filtro a las imágenes antes de realizar la clasificación. En este caso es conveniente usar filtros medianos u otro tipo de filtro que no afecte tanto a los bordes y solo suavice las partes más uniformes.

5. APLICACIÓN PRÁCTICA

El objetivo del presente trabajo es evaluar la efectividad de las técnicas de clasificación por contexto; por lo tanto, para la aplicación práctica de las metodologías anteriormente descritas, se eligió obtener el mapa de uso de suelo de una zona que tuviera una presencia significativa de área urbana. Debido a que este tipo de áreas en particular presentan una gran heterogeneidad y consecuentemente en estas situaciones es muy útil tomar en cuenta el contexto espacial.

Para tal efecto se ocupó una imagen multispectral TM, con sus 7 bandas espectrales, correspondiente al oeste de Guadalajara. La imagen con que se contó es un recorte de la escena original, el cual esta compuesto por 866 columnas y 780 líneas. Abarca la parte oeste de la ciudad de Guadalajara, el bosque de La Primavera y sus alrededores. La imagen fue obtenida en abril de 1992.

El procesamiento de la imagen se realizó con el software de análisis geográfico IDRISI, en su versión win32, el cual es un sistema de información geográfica y de procesamiento de imágenes, desarrollado por la *Clark University Graduate School of Geography*. Este software se corrió sobre plataforma Windows en una PC.

Para comenzar con el procesamiento de la imagen, se obtuvieron los histogramas de la imagen en cada una de sus bandas (Fig. 5.1 - 5.7). En las bandas se notaba claramente que las imágenes contaban con un contraste pobre, lo cual se corroboró al intentar desplegar las imágenes, notando que no eran útiles para un primer análisis visual. Se aplicó, entonces, un realce de contraste a cada una de las bandas. La técnica elegida fue la de realce lineal con saturación de un 5%, esto debido a que se ocuparían las imágenes solamente para un análisis visual, en el cual no importa si los valores de cada píxel cambian. Por otro lado se decidió no ocupar la técnica de ecualización del histograma puesto que, si bien no importa que los valores de los píxeles cambien, tampoco es útil que la imagen pierda su proporción real, cosa que sucede en la ecualización del histograma.

Se hizo un análisis de la información visual que aportaba cada banda realizada linealmente (Fig. 5.8 - 5.14), considerando cuáles serían útiles en la clasificación de uso de suelo y con la limitante de que para hacer un análisis de este tipo se necesita bastante experiencia, se obtuvieron las siguientes observaciones:

- En la banda 4, se hace bastante clara y evidente la morfología del terreno.
- En la banda 3 (la cual contrasta las zonas de vegetación y suelo desnudo), se distinguen las zonas con vegetación (oscuras) y las que carecen de ésta (claras).
- La banda 6 presenta poco contraste, lo cual nos corrobora que esta banda agrega poca información a la clasificación.

Al hacer un análisis visual, si bien se requiere de mucha práctica para obtener resultados ciertos, se puede empezar a distinguir generalidades del terreno y comenzar a

familiarizarse con el área de trabajo. Para esta familiarización es también muy útil el ocupar mapas de la zona para conocer las generalidades del área de estudio.

Otra técnica importante de análisis visual es la de composición en color; pues esta nos permite, a partir de la asignación de bandas espectrales a los distintos canales RGB, y observar en color áreas dentro de la imagen (Fig. 5.15 y Fig. 5.16). En el caso de la imagen con la cual se trabajó, se realizaron varias pruebas de composiciones en color, las cuales se hicieron agregándole un realce lineal con saturación de 2.5 % para maximizar la información visual que se obtuvo de estas. La asignación de bandas a los canales depende mucho de la información que se pretenda obtener, o bien de las preferencias del analista. En este caso, como lo que se pretende es obtener información general acerca del área de análisis, son de especial interés las composiciones en las cuales se contrastan mejor las áreas. Por otro lado es muy útil la composición llamada comúnmente falso color de infrarrojo, la cual consiste en poner las bandas 2, 3 y 4 en los canales azul, verde y rojo respectivamente (Fig. 5.16). Para esta composición, se observó que el área central de la imagen está constituida principalmente por tonos del rojo oscuro, lo cual es indicativo de vegetación. Parte de la porción derecha de la imagen varía de tonos grises a azules metálicos, lo cual indica áreas urbanas. Se notan también porciones pequeñas en tonos rojos claros, bien definidas en sus contornos; lo cual indica vegetación vigorosa. Pero tomando en cuenta sus contornos definidos se puede inferir que se trata de zonas agrícolas de riego, pues por la época del año en que fue obtenida la imagen no se puede tratar de zonas de riego de temporal. Por último, se pueden identificar las zonas del contorno de la imagen que se aprecian en tonos de grises (pero no tan claros como la zona urbana) y que corresponden a suelo desnudo; o en este caso a campos de cultivo de temporal, tomando en cuenta sus contornos definidos y la época del año en que se obtuvo la imagen.

Una vez que se tiene una visión general del área de estudio, así como los objetivos mismos del estudio, se puede tomar la decisión acerca de qué bandas espectrales se usarán para la clasificación. Si bien es muy recomendable contar con la máxima cantidad de información, muchas veces se debe restringir el uso de ciertas bandas, por considerar que estas pueden provocar ruido o introducir información que confunda los resultados. En este caso, se tomó la decisión de eliminar la banda 6, debido a que no cuenta con un buen contraste y aporta poca información. Además, es importante considerar que la banda 6 del TM originalmente tiene una resolución espacial distinta a las demás bandas (120 m de la banda 6 contra los 30 m del resto de las bandas), que introduce cantidades considerables de ruido al hacer el ajuste para que coincidan estas resoluciones. El resto de las bandas sí serán ocupadas en la clasificación, puesto que, como ya se mencionó, es preferible contar con el máximo de información.

Analizando los histogramas de las bandas de la imagen, se observa que estos no tienen sus valores iniciales en los primeros valores posibles de brillantez. Esto se considera como una alteración atmosférica en los valores de la imagen al obtener el sensor los valores de brillantez de cada píxel. Para corregir este problema, se le aplica al conjunto de imágenes una técnica de corrección atmosférica llamada corrección del histograma por sus valores mínimos (*Histogram Minimum Method*, HMMM; Apéndice 1), para hacer que los histogramas comiencen desde el primer valor, eliminando así los efectos de la alteración atmosférica.

Para la etapa de clasificación se optó por una metodología híbrida, la cual consiste en hacer primero una clasificación no supervisada. Posteriormente esta imagen es utilizada para

delimitar los campos de entrenamiento, ya que contiene zonas con valores bastante homogéneos. Estos datos se complementan con información auxiliar como lo son mapas o bien las composiciones en color.

Para la clasificación no supervisada, se eligió el método de pico del histograma (*Histogram peak*) el cual consiste en encontrar los picos de los histogramas para formar los clusters a partir de estos y posteriormente agruparlos tal y como se describió en la sección dedicada a este tema. Para lograr un histograma sencillo a partir de uno multiespectral, un camino es reducir la cantidad de datos (sin perder información), mediante el análisis de componentes principales (PCA), y posteriormente crear una composición a color de 8 bits de las 3 principales bandas del PCA; las cuales regularmente contienen la mayor parte de la información, para así tener representado en un solo histograma la mayor parte de la información.

En el caso práctico que se estudia en el presente trabajo, el PCA se realizó sobre las bandas TM 1, 2, 3, 4, 5 y 7, pues como ya se mencionó se eliminó del análisis la banda 6. Los resultados del PCA se muestran en la tabla 5.1. En esta se puede observar que las 3 primeras componentes contienen el 99.3% de la varianza total, lo cual indica que por sí solas estas 3 componentes aportan la mayor parte de la información. Por otro lado también se puede ver como la primer componente por sí misma esta compuesta por la mayor parte de la información de todas las bandas originales. La segunda componente contiene información de las bandas visibles originales, y una parte considerable de la banda del infrarrojo. Por último la tercera componente esta formada principalmente por la banda del infrarrojo.

Para poder realizar una composición a color de las 3 primeras componentes del PCA, se tiene que realizar sobre éstas un ajuste lineal de su contraste, para hacer que sus valores de brillantez estén dentro del rango de 0 a 255. En este caso no se considera ninguna saturación, pues no es conveniente modificar demasiado los valores brillantez. En esta composición a color no importa mucho el orden de las componentes, puesto que no se utilizará para análisis visual.

Después de realizar varias pruebas de clasificación no supervisada, variando la cantidad de clases finales en la clasificación, se observó que el número de clases que correspondía mejor con la información que se obtuvo del análisis visual, es decir, que se correspondieran de manera más clara con las zonas de color más o menos homogéneas en las composiciones a color previamente obtenidas, era de 8 clases temáticas (Fig. 5.17).

Tabla 5.1 Estadísticas obtenidas del Análisis de Componentes Principales (PCA)

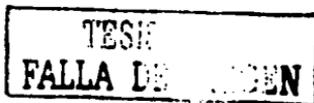
VAR/COVAR	b1	b2	b3	b4	b5	b7
b1	140.19	91.55	142.72	80.89	255.76	185.68
b2	91.55	61.81	96.26	57.89	174.04	124.83
b3	142.72	96.26	153.92	88.75	287.16	205.06
b4	80.89	57.89	88.75	88.90	169.16	109.20
b5	255.76	174.04	287.16	169.16	666.39	446.90
b7	185.68	124.83	205.06	109.20	446.90	317.24
COR MATRIX	b1	b2	b3	b4	b5	b7
b1	1.000000	0.983511	0.971591	0.724622	0.836777	0.880499
b2	0.983511	1.000000	0.986887	0.780947	0.857538	0.891500
b3	0.971591	0.986887	1.000000	0.758755	0.896625	0.927983
b4	0.724622	0.780947	0.758755	1.000000	0.695011	0.650259
b5	0.836777	0.857538	0.896625	0.695011	1.000000	0.971976
b7	0.880499	0.891500	0.927983	0.650259	0.971976	1.000000
COMPONENT	C 1	C 2	C 3	C 4	C 5	C 6
% var.	91.98	4.76	2.56	0.44	0.21	0.04
eigenval.	1313.92	68.01	36.63	6.35	2.97	0.55
eigvec.1	0.297454	0.496127	-0.366203	-0.187773	-0.655065	-0.258661
eigvec.2	0.202082	0.327144	-0.130823	-0.083683	0.078691	0.906548
eigvec.3	0.327749	0.379665	-0.230329	-0.182935	0.745878	-0.324938
eigvec.4	0.192786	0.485595	0.795463	0.294938	-0.045387	-0.072253
eigvec.5	0.701240	-0.474271	0.281654	-0.444123	-0.079363	0.021371
eigvec.6	0.484108	-0.204826	-0.289203	0.800025	-0.002290	-0.001686

TESIS CON
 FALLA DE ORIGEN

LOADING	C 1	C 2	C 3	C 4	C 5	C 6
b1	0.910647	0.345564	-0.187180	-0.039965	-0.095373	-0.016271
b2	0.931741	0.343171	-0.100707	-0.026824	0.017255	0.085886
b3	0.957599	0.252376	-0.112357	-0.037158	0.103639	-0.019508
b4	0.741164	0.424735	0.510583	0.078829	-0.008298	-0.005708
b5	0.984661	-0.151514	0.066030	-0.043355	-0.005300	0.000617
b7	0.985226	-0.094838	-0.098266	0.113191	-0.000222	-0.000071

Para la realización de los campos de entrenamiento, se ocupó la imagen obtenida de la clasificación no supervisada; así como las composiciones a color previamente obtenidas, y mapas que se obtuvieron de la zona. Tomando en cuenta toda esta información y siguiendo los tipos de cubierta que serían los más útiles en este caso de entre los más usados comúnmente, se definieron 7 tipos de cubierta para definir los campos de entrenamiento y posteriormente las firmas espectrales. Estos tipos son:

1. Agricultura de temporal.
2. Agricultura de riego.
3. Vegetación 1.
4. Vegetación 2.
5. Bosque.
6. Suelo desnudo.
7. Urbano.



Si bien la situación óptima para desarrollar los campos de entrenamiento es tener bastante información clara y fidedigna de la zona, para así poder delimitar las áreas donde mejor se representa cada tipo de cubierta, en la aplicación de este caso práctico no se contó con este tipo de información. Los mapas con los cuales se contó eran muy antiguos comparados con la fecha de adquisición de la imagen, y a su vez no marcaban de forma clara los tipos de cubierta o bien contenían clasificaciones muy específicas que para este caso no eran útiles.

Sin embargo, el obtener los campos de entrenamiento con este método híbrido, permite al usuario utilizar campos de entrenamiento sobre zonas con las cuales no se cuenta mucha información; o bien la creación de éstos por personas con conocimientos básicos acerca del tema en particular o sin mucha experiencia en el desarrollo de campos de entrenamiento. Esto es debido a que para la formación de los campos de entrenamiento, se parte de áreas homogéneas (obtenidas de la clasificación no supervisada) para ir determinando el número y tipo de clases espectrales, las cuales son reconocidas mediante la información auxiliar, o mediante la coincidencia de éstas. Por otro lado, en la forma tradicional de obtener los campos de entrenamiento, se parte de información fidedigna sobre las zonas para encontrar áreas homogéneas en la imagen. Cabe mencionar que, si bien esta metodología facilita el trabajo y

proporciona cierta flexibilidad, puede conducir a que un analista sin mucha experiencia haga un reconocimiento erróneo de las cubiertas terrestres. Es decir, que tome un tipo de cubierta por otro, o bien se de el traslape de éstas. Es también importante recordar que el tamaño de los campos de entrenamiento debe de ser por lo menos 10 veces mayor que el número de bandas que se utilicen. En esta aplicación, se cuidó que el número de píxeles para cada firma espectral sobrepasara holgadamente este número de 70 píxeles.

Una vez definido el campo de entrenamiento (Fig. 5.18), se obtienen las firmas espectrales que definen estos campos de entrenamiento. Es muy importante hacer el análisis de estas firmas espectrales, puesto que si no están bien definidas de forma que se puedan discriminar las cubiertas que representan, los métodos de clasificación que se ocupen posteriormente arrojarán resultados erróneos y confusos. El análisis de las firmas espectrales para esta aplicación práctica se realizó de forma gráfica usando el diagrama de firmas espectrales (Fig. 5.19). En este diagrama se puede observar que la mayoría de las firmas espectrales se encuentran separadas considerablemente en la mayoría de las bandas, o bien, se producen cruces una banda a otra entre firmas en las cuales podría existir alguna confusión. Tal es el caso para las firmas espectrales que representan *Vegetación 1* y *Bosque*. Se eligió este método de análisis, puesto que es el más útil para determinar si las firmas espectrales podrán ser empleadas o no para una clasificación por máxima verosimilitud.

Después de analizar las firmas espectrales, se debe tomar la decisión de continuar con la clasificación por medio de alguno de los métodos supervisados existentes, o bien volver a definir los campos de entrenamiento. O más aún, volver a definir el número y significado de las firmas espectrales, si es que se ve que existe demasiada confusión entre éstas.

La elección del método de clasificación que se utilizará en última instancia, depende mucho de los resultados que se esperen obtener, las características de la imagen, y el equipo con el que se cuente para procesar la imagen. En este caso en particular, se optó por ocupar como método por píxel al de máxima verosimilitud. Esto debido a que es el método que más se ocupó en los trabajos consultados previamente, y se acostumbra mucho presentarlo como marco de referencia y comparación con otros métodos. Además, también se ha comprobado que es el método tradicional que arroja mejores resultados, si bien antes se consideraba que consumía grandes recursos computacionales. Esto último, gracias al aumento en el poder computacional de los equipos, no representó en este trabajo mayor dificultad, esto sin considerar que la imagen con la que se trabajó no era realmente grande, pues era una sección de la escena completa.

Para realizar la clasificación por máxima verosimilitud se ocuparon las firmas espectrales que se mencionan anteriormente asignándoles una probabilidad de ocurrencia igual a cada una de ellas. A su vez se ocuparon las 6 bandas UTM originales (sin tomar en cuenta la banda 6) corregidas atmosféricamente. La imagen resultante se presenta en la figura 5.20. En esta imagen se observó que las categorías de vegetación se hallaban muy mezcladas, por lo que se tomó la decisión de fusionar ambas categorías en una sola categoría general de *Vegetación*. El resultado de esta fusión derivó en un mapa de clasificación temática mucho más homogéneo (Fig. 5.21).

Aún con la fusión de las categorías de vegetación, en el mapa se observa el efecto "*salt and pepper*", sobre todo en las áreas urbanas, y entre las categorías de vegetación y bosque. Para reducir este efecto se aplicó, a la imagen obtenida por el método de máxima verosimilitud, un filtro modal, el cual es una de las técnicas de clasificación por contexto. La decisión de utilizar esta técnica por encima de las otras, se debió a que esta técnica es muy sencilla y se ha observado que los resultados obtenidos de ésta son muy buenos. También se tomó esta decisión, tomando en cuenta que uno de los objetivos del presente trabajo es mejorar el desempeño de una clasificación temática, usando métodos de clasificación por contexto, sin necesidad de aumentar el gasto computacional o la dificultad de la implementación.

El resultado de aplicar el filtro modal a la imagen clasificada por máxima verosimilitud, se muestra en la figura 5.22. En esta imagen se observa claramente que el efecto "*salt and pepper*" se reduce significativamente.

Se probó también otra técnica de clasificación por contexto que se vale de filtros para mejorar la clasificación. Esta otra técnica, a diferencia de la anterior, consiste en aplicar el filtro a las imágenes antes de realizar la clasificación. Se han mencionado en el presente trabajo los riesgos de procesar con filtros las imágenes que serán ocupadas en la clasificación. Esta técnica intenta minimizar los riesgos de excesiva modificación de los valores de brillantez originales, mediante el uso de un filtro que no modifique o suavice los contrastes de la imagen, sino que sólo suavice las áreas que son más o menos homogéneas. Este filtro es el filtro de mediana, el cual se describe en la sección que se refiere a los filtros en el presente trabajo. Además, se justifica el empleo de esta técnica y la modificación de los píxeles originales, si se recuerda que todas las técnicas de clasificación se basan realmente en valores relativos de los píxeles, y no en medidas absolutas o fijas. Es decir, que mientras los píxeles conserven la proporción correcta entre sus valores, el resultado final no tiene porque variar demasiado.

En este caso, el filtro modal se aplicó en cada una de las 6 imágenes originales TM corregidas atmosféricamente. Una vez filtradas las imágenes, se ocupan éstas para realizar una clasificación por máxima verosimilitud, de forma similar a la que se describió anteriormente y con las mismas firmas espectrales desarrolladas e iguales probabilidades de ocurrencia para cada una de éstas firmas espectrales. El resultado de este proceso es muy similar al de la clasificación por máxima verosimilitud original (con 7 clases temáticas), sin embargo, se nota claramente la reducción del efecto de sal y pimienta (Fig. 5.23). Después de fusionar las clases de vegetación, de forma similar a la anterior, la imagen que resulta (Fig. 5.24) es muy similar a la obtenida de aplicar el filtro modal a la imagen clasificada.

De esta forma, se obtuvieron 3 distintas clasificaciones temáticas o mapas de uso de suelo del área oeste de Guadalajara, mediante 3 técnicas distintas: máxima verosimilitud, filtro modal (posclasificación) y filtro mediano (preclasificación).

Haciendo un recuento de los pasos que se siguieron para obtener estos tres mapas de uso de suelo, se obtienen los lineamientos de una metodología de clasificación de imágenes multiespectrales que incluye técnicas no supervisadas, supervisadas y por contexto. A simple vista se observa que los resultados más homogéneos, y por lo tanto los más útiles en última instancia, son los obtenidos a partir de las técnicas que incluyen la información contextual.

Además, la metodología propuesta cuenta con la ventaja de no requerir muchos conocimientos previos sobre la zona, o bien mucha experiencia en el desarrollo de mapas de uso de suelo.

La metodología propuesta se puede resumir en los siguientes pasos:

- I. Definición del área de estudio.
- II. Obtención de información general a partir de análisis visual e información auxiliar (mapas, estadísticas, etc.).
- III. Elección de bandas a usarse para la clasificación.
- IV. Corrección de las imágenes (en este caso sólo fue necesaria la corrección atmosférica, pero quizá sea necesario en otros casos realizar otro tipo de correcciones: Richards, 1993; Jensen, 1996; Chuvieco, 1990; y otras obras relacionadas al procesamiento digital de imágenes de Percepción Remota).
- V. Clasificación no supervisada para obtener zonas homogéneas espectralmente dentro de la imagen (en este caso, como se utilizó la técnica del pico del histograma, se necesitó hacer un análisis de componentes principales y luego con las 3 primeras componentes una composición a color, pero en este paso muy bien se puede ocupar alguna otra técnica de clasificación no supervisada).
- VI. Definición del número y tipo de clases temáticas, a partir de la clasificación no supervisada y de la información auxiliar.
- VII. Realización de los campos de entrenamiento, partiendo de la imagen obtenida en la clasificación no supervisada y utilizando la información obtenida a partir del análisis visual e información auxiliar.
- VIII. Obtención de firmas espectrales.
- IX. Análisis de las firmas espectrales y evaluación de si éstas son lo suficientemente buenas para continuar con la clasificación, o bien repetir la obtención de firmas espectrales, ya sea volviendo a realizar los campos de entrenamiento (paso VII) o volviendo a plantear el número y tipo de clases temáticas (paso VI), según se estime necesario.
- X. Aplicación del método de máxima verosimilitud utilizando las bandas espectrales originales corregidas y las firmas espectrales obtenidas y evaluadas en los pasos anteriores.
- XI. Definir si el mapa resultante es lo suficientemente claro como para expresar los resultados deseados. Si no es así, fusionar clases temáticas que sean muy particulares para obtener algunas otras más generales; o en caso contrario, regresar a la definición del número y tipo de clases temáticas (paso VI), para separar clases temáticas que sean muy generales, en clases más particulares.
- XII. Definir si el mapa resultante es lo suficientemente homogéneo (no presenta el efecto "salt and pepper"), si no es así aplicar un filtro modal a la imagen obtenida previamente, para suavizar los resultados.

Como se podrá observar, en la definición de la metodología se optó por ocupar el filtro posclasificación y no el filtro preclasificación. Esto es debido a que, si bien los resultados lucen a simple vista muy similares, el trabajo de aplicar los filtros es mucho mayor en el caso de la preclasificación; pues el filtro se aplica a cada una de las imágenes de las bandas

TESIS CON
FALLA DE ORIGEN

espectrales. Por otro lado, el filtro posclasificación se aplica una sola vez al mapa temático obtenido al final del proceso.

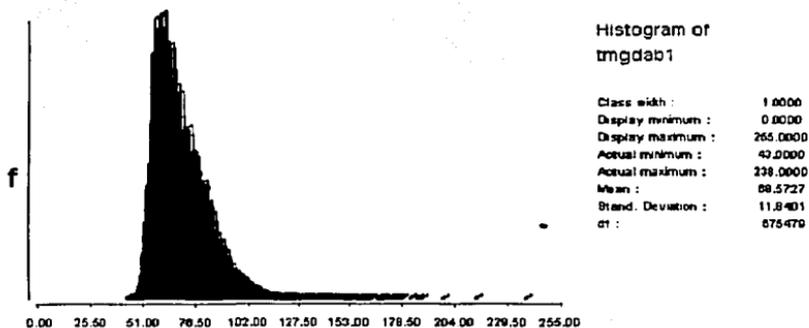


Fig. 5.1 Histograma de la banda 1 TM de la imagen del oeste de Guadalajara.

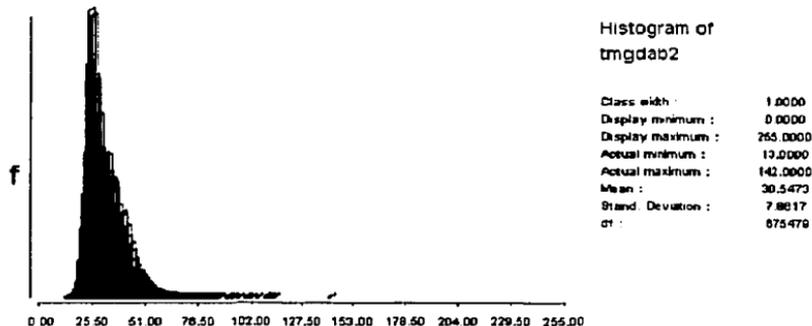


Fig. 5.2 Histograma de la banda 2 TM de la imagen del oeste de Guadalajara.

TESIS CON
FALLA DE ORIGEN

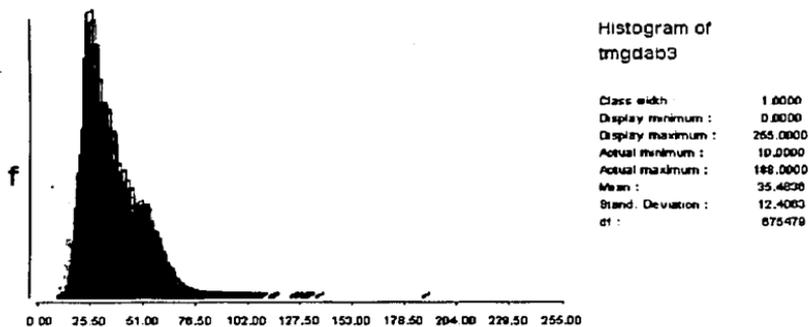


Fig. 5.3 Histograma de la banda 3 TM de la imagen del oeste de Guadalajara.

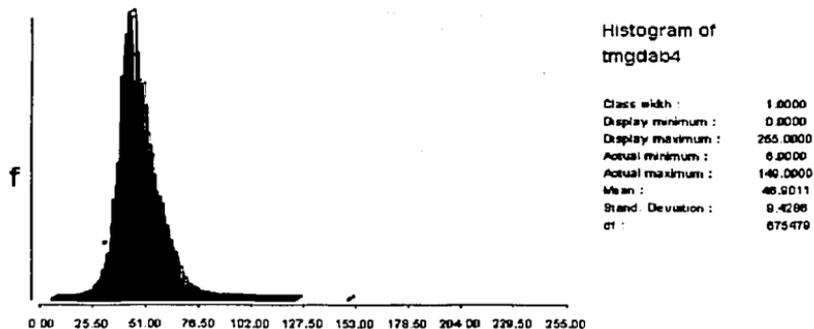


Fig. 5.4 Histograma de la banda 4 TM de la imagen del oeste de Guadalajara.

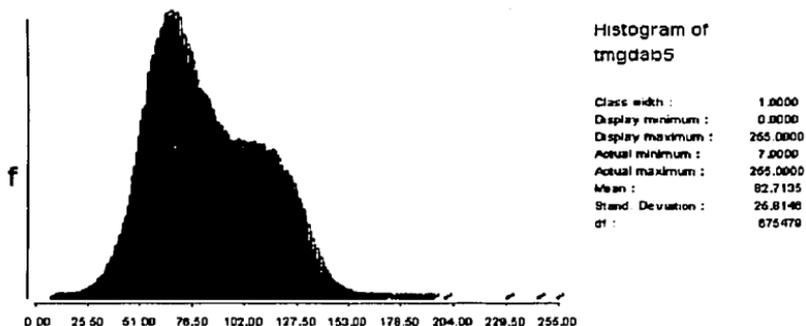


Fig. 5.5 Histograma de la banda 5 TM de la imagen del oeste de Guadalajara.

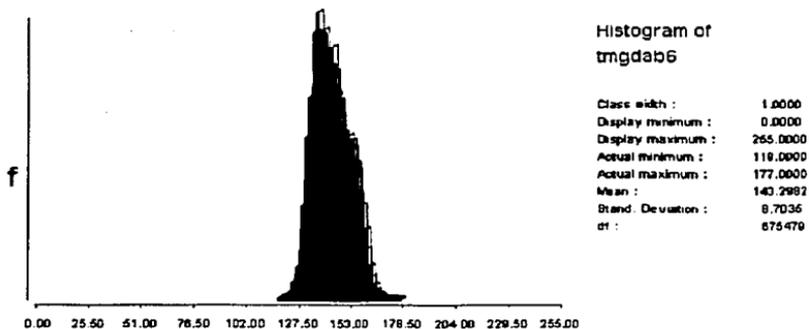


Fig. 5.6 Histograma de la banda 6 TM de la imagen del oeste de Guadalajara.

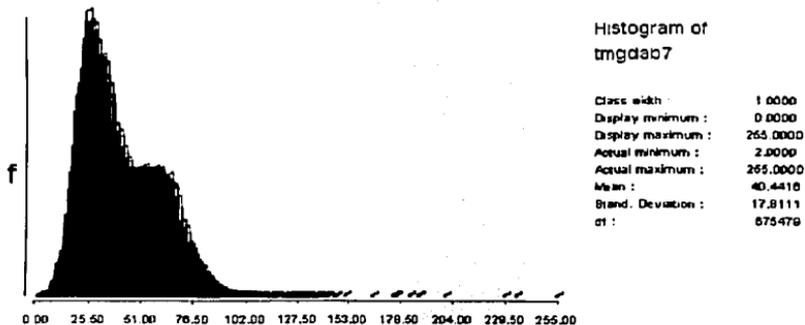


Fig. 5.7 Histograma de la banda 7 TM de la imagen del oeste de Guadalajara.

TESIS CON
FALLA DE ORIGEN



Fig. 5.8 Imagen de la banda 1 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE ORIGEN



Fig. 5.9 Imagen de la banda 2 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE ORIGEN



Fig. 5.10 Imagen de la banda 3 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE CARGEN



Fig. 5.11 Imagen de la banda 4 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE ORIGEN



Fig. 5.12 Imagen de la banda 5 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE ORIGEN



Fig. 5.13 Imagen de la banda 6 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE ORIGEN



Fig. 5.14 Imagen de la banda 7 TM de la imagen del oeste de Guadalajara realizada linealmente con saturación del 5%.

TESIS CON
FALLA DE ORIGEN

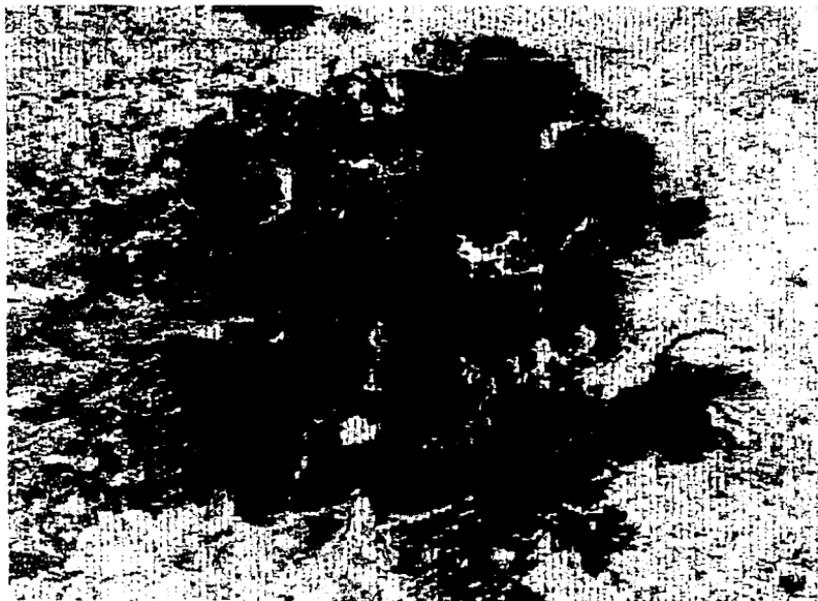


Fig. 5.15 Composición en color RGB de las bandas 1, 2 y 3 TM de la imagen del oeste de Guadalajara (Composición de Color Real).

TESIS CON
FALLA DE ORIGEN



Fig. 5.15 Composición en color RGB de las bandas 2, 3 y 4 TM (también llamada composición en falso color) de la imagen del oeste de Guadalajara.

TESIS CON
FALLA DE ORIGEN

Clasificación no supervisada (8 clases)



Fig. 5.17 Clasificación no supervisada con 8 clases temáticas de la imagen del oeste de Guadalajara.

TESIS CON
FALLA DE ORIGEN



Fig. 5.18 Delimitación de los campos de entrenamiento tomando en cuenta 7 clases temáticas (el 0 es el valor de fondo), de la imagen del oeste de Guadalajara.

TESIS CON
FALLA DE ORIGEN

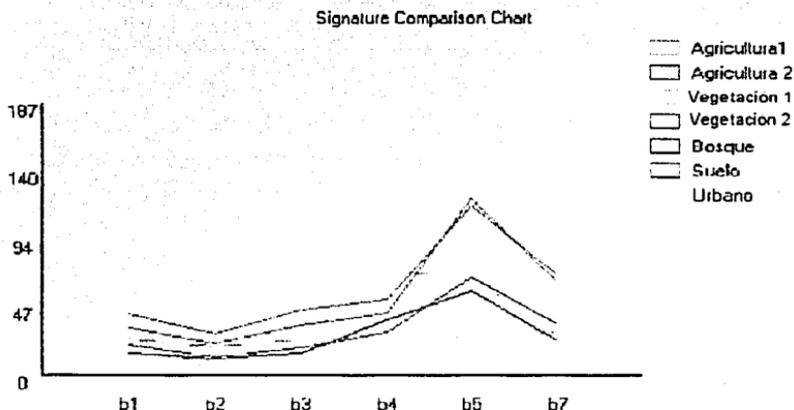


Fig. 5.19 Diagrama de firmas espectrales obtenidas del campo de entrenamiento para la imagen del oeste de Guadalajara.

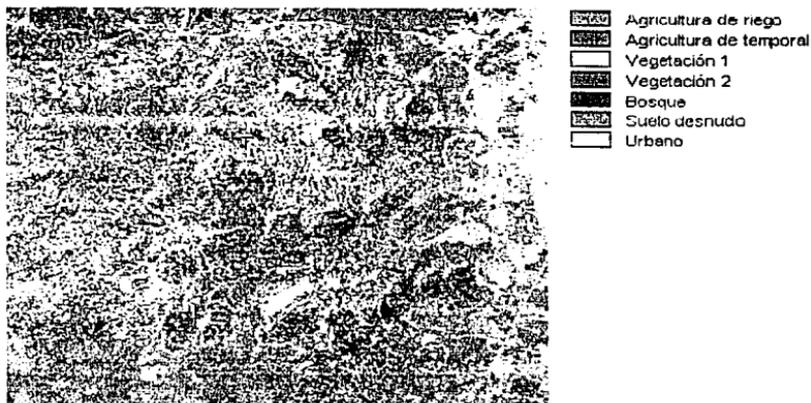


Fig. 5.20 Mapa de uso de suelo (con 7 clases temáticas) para la zona oeste de Guadalajara obtenida a partir de la clasificación por máxima verosimilitud.

TESIS CON
 FALLA DE ORIGEN

Máxima verosimilitud



- | | |
|--|-------------------------|
| | Agricultura de riego |
| | Agricultura de temporal |
| | Vegetación |
| | Bosque |
| | Suelo desnudo |
| | Urbano |

Fig. 5.21 Mapa de uso de suelo (con 6 clasificaciones temáticas) para la zona oeste de Guadalajara obtenido a partir de la clasificación por máxima verosimilitud.

Postclasificación contextual (F-filtro modal)



- | | |
|--|-------------------------|
| | Agricultura de riego |
| | Agricultura de temporal |
| | Vegetación |
| | Bosque |
| | Suelo desnudo |
| | Urbano |

Fig. 5.22 Mapa de uso de suelo (con 6 clasificaciones temáticas) para la zona oeste de Guadalajara obtenido a partir de un filtraje postclasificación con un filtro modal.



Fig. 5.23 Mapa de uso de suelo (con 7 clases temáticas) para la zona oeste de Guadalajara obtenido a partir de un filtraje preclasificación con un filtro mediano.

Máxima verosimilitud filtrado previamente con un filtro de mediana

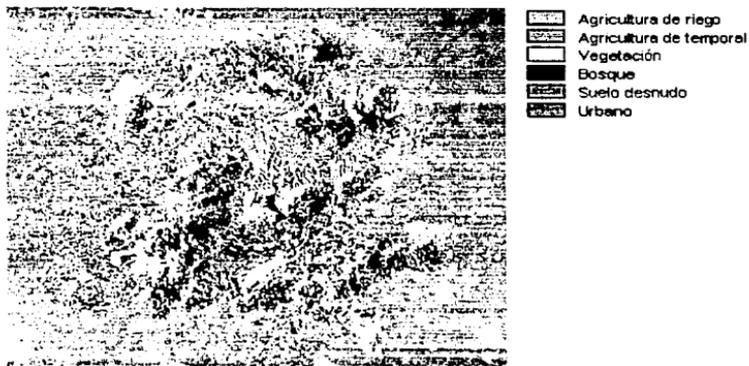


Fig. 5.24 Mapa de uso de suelo (con 6 clases temáticas) para la zona oeste de Guadalajara obtenido a partir de un filtraje preclasificación con un filtro de mediana.

6. COMPARACIÓN Y EVALUACIÓN DE RESULTADOS

En el anterior capítulo, en relación con las imágenes resultantes de la aplicación práctica, se hicieron comentarios acerca de que método "Lucía" a simple vista mejor, y acerca de cual método economizaba los recursos computacionales y disminuía a la vez el proceso. Se llegó pues a la conclusión de que, tomando en cuenta los aspectos anteriores, el método de clasificación por contexto que consiste en aplicar un filtro modal posclasificación es el método que a simple vista parece ser el más efectivo. Sin embargo, esta estimación es solo subjetiva, puesto que no hay ninguna medida confiable o ningún parámetro fijo para sustentar esta conclusión.

6.1 Bases teóricas

Existen métodos de verificación estadística que se han desarrollado en el contexto del procesamiento digital de imágenes espaciales. La estimación de la exactitud alcanzada por el mapa puede realizarse por diversos criterios: (i) comparando el inventario de la clasificación con el obtenido por otras fuentes convencionales; (ii) estudiando la fiabilidad obtenidas al utilizar las áreas de entrenamiento, y (iii) seleccionando algunas áreas de verificación para las que se cuenta con la cubierta realmente presente en el suelo (Fig. 6.1).

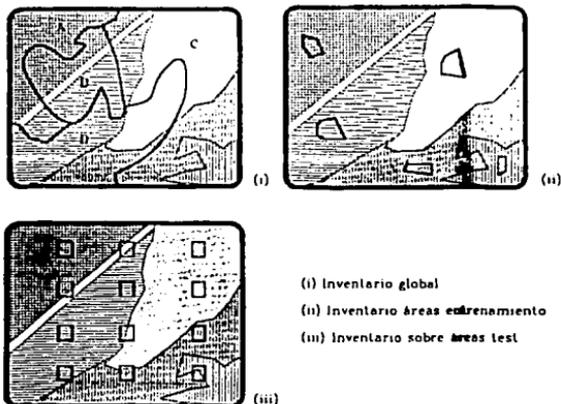


Fig. 6.1 Medidas de fiabilidad en una clasificación.

El método más sencillo para estimar la precisión conseguida por un mapa, se basa en calcular las diferencias entre el inventario ofrecido por la clasificación y por otras fuentes que se consideren fiables (estadísticas oficiales, cartografía de detalle, etc.). Suponiendo al documento de referencia como plenamente fiable, esta medida sólo indica el porcentaje de error, pero no su localización sobre el mapa. Además, no siempre resulta sencillo ajustar la leyenda de la fuente convencional con la obtenida a partir de imágenes de satélite.

Otra opción para verificar los resultados, consiste en utilizar los campos de entrenamiento, para comprobar si se ajustan correctamente a las categorías que pretenden definir. Se trata ésta de una medida de la fiabilidad un tanto sesgada. Si las áreas de entrenamiento sirven para definir estadísticamente a las distintas categorías, parece lógico que los píxeles incluidos en ellas tengan una mayor probabilidad de clasificación certera que el resto de los píxeles de la imagen. Ahora bien, aunque no puede calificarse como un criterio riguroso de validación, esta práctica resulta muy interesante para explorar la "pureza" de cada campo de entrenamiento, o, dicho de otro modo, la precisión con la que identifican a un determinado tipo de cubierta. De la misma forma, puede considerarse un método que medirá la efectividad con que actúa el método de clasificación, sin tomar en cuenta si se apega o no a la realidad. Si los píxeles incluidos en estas áreas se asignan a otras clases, conviene delimitar nuevos campos de entrenamiento y/o simplificar la leyenda de trabajo.

La tercera vía de trabajo consiste en seleccionar, con posterioridad a la clasificación, una serie de áreas de prueba, que permitan obtener una medida independiente del acuerdo entre mapa y verdad-terreno. Este procedimiento pasa por realizar un muestreo del área de estudio, a fin de obtener las medidas de campo necesarias para verificar los resultados de la clasificación. Tal muestreo supone un coste adicional al proyecto, que, además, no repercute en una mejora de su fiabilidad, sino sólo en la medida de ésta.

A partir de la realización del muestreo, puede construirse una tabla o matriz de confusión, en donde se resumen los acuerdos y desacuerdos entre clases del mapa y del terreno. Esta matriz puede analizarse estadísticamente, con objeto de obtener una serie de medidas sobre la fiabilidad del trabajo: global y para cada una de las categorías.

El diseño y desarrollo del muestreo supone la columna vertebral del proceso de verificación. Al igual que en otras aplicaciones, el muestreo espacial sirve en este caso para seleccionar una pequeña parte del área de estudio, de tal forma que sea suficientemente representativa del conjunto. Esa semejanza con la población de referencia debe conseguirse, además, minimizando el tamaño de la muestra, con objeto de reducir los costes del proceso de verificación. En definitiva, la principal virtud de un buen muestreo es seleccionar adecuadamente una parte de la imagen clasificada, de tal forma que, siendo tan pequeña como sea posible, sea a la vez suficientemente representativa del conjunto. Esa semejanza depende de una serie de factores, que se consideraran al planificar el muestreo: (i) método de selección de la muestra, (ii) tamaño y distribución, y (iii) nivel de confianza otorgado a la estimación.

Los esquemas más regularmente empleados para seleccionar la muestra son (Campbell, 1987; Congalton, 1988b):

- i. Aleatorio simple. Los elementos a verificar se eligen de tal forma que todos cuenten con la misma probabilidad de ser seleccionados, y que la elección de uno no influya en la del siguiente. Gracias a este carácter probabilístico, el muestreo aleatorio es el más sólido estadísticamente, si bien presenta problemas en su aplicación espacial, pues existe cierta probabilidad de no recoger adecuadamente la variación espacial presente en la imagen clasificada (Fig. 6.2a).
- ii. Aleatorio estratificado. La muestra se realiza dividiendo la población en regiones o estratos, de acuerdo a una variable auxiliar (altitud, por ejemplo). Es más complejo de diseñar que el anterior, pero aporta información sobre subconjuntos de la población, además de reducir el error de muestreo si la variable auxiliar se elige correctamente (Fig. 6.2b).
- iii. Sistemático. La muestra se distribuye a intervalos regulares, a partir de un punto de origen señalado aleatoriamente. Garantiza un muestreo completo de la superficie a verificar, pero puede facilitar estimaciones erróneas si existe algún tipo de patrón periódico en el área observada (geometría de las parcelas, por ejemplo). Por otro lado, no asegura una estimación probabilística, por cuanto no existe aleatoriedad en la selección de las observaciones (Fig. 6.2c).
- iv. Sistemático no alineado. Modifica el esquema anterior, gracias a variar aleatoriamente una de las dos coordenadas (Fig. 6.2d). Esto permite introducir una cierta aleatoriedad en la elección de la muestra, mientras reduce el sesgo debido a la periodicidad. Por otra parte, sigue garantizando una revisión completa del territorio.
- v. Por conglomerados. Se selecciona como unidad de muestra un grupo de observaciones, denominado conglomerado (cluster), en lugar de individuos aislados. En otras palabras, en cada punto a verificar se toman varias muestras, en puntos vecinos al elegido aleatoriamente, y de acuerdo a un esquema prefijado. Por ejemplo, un conglomerado podría constituirse por cinco puntos, a cierta distancia del punto central y siguiendo una forma de L (Fig. 6.2e). Este método de muestreo reduce los costos, pero resulta más complejo y, normalmente menos preciso que los anteriores.

En cuanto al tamaño de la muestra, Congalton (1988b) sugiere una superficie aproximada al 1% de la superficie cartografiada. En éste, como en otros muestreos, el tamaño de la muestra depende del nivel de probabilidad, o de confianza, que quiera otorgarse a la estimación, así como de la propia variabilidad de la imagen considerada. Como se trata de una variable binomial (acierto-error), se emplea normalmente la fórmula:

$$n = \frac{z^2 p q}{E^2} \quad [6.1]$$

donde z es la abscisa de la curva normal para un nivel determinado de probabilidad; p indica el porcentaje de aciertos estimado; q , el de errores ($q = 1 - p$), y E , el nivel permitido de error. El valor de p y q puede estimarse a partir de datos auxiliares o simplemente igualarse a 50. Según algunos autores, se precisan un mínimo de 50 puntos de verificación para obtener una estimación fiable del error (Hay, 1979).

Una vez diseñado el método y tamaño de la muestra, y localizados los puntos de verificación, el paso siguiente consiste en obtener, para cada uno de ellos, la clase real y la

deducida de la clasificación. La primera puede obtenerse a partir de trabajos de campo o de documentos auxiliares de mayor detalle (fotografías aéreas, mapas de cultivo o vegetación), mientras la segunda se adquiere de la imagen clasificada.

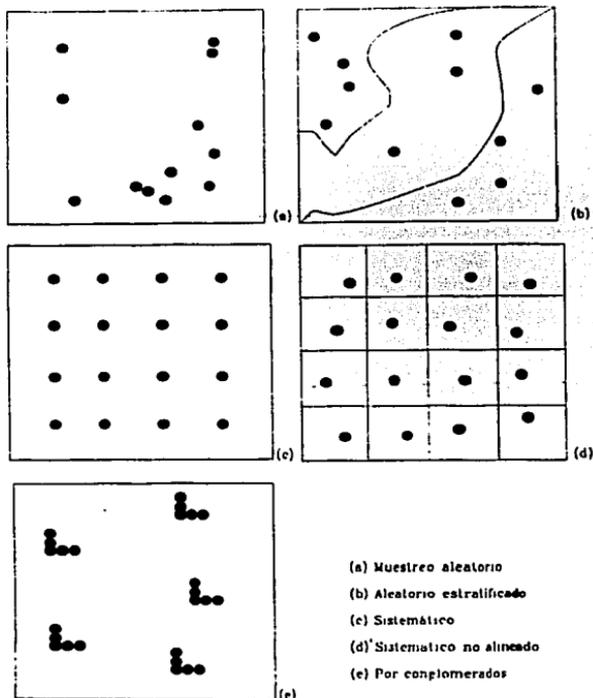


Fig. 6.2 Tipos de muestreo aplicados a la verificación.

Como consecuencia de la fase de muestreo, se tendrá un listado de puntos de prueba, para los que se tiene tanto su cobertura real como la deducida por la clasificación. Con estos datos puede formarse una matriz, denominada de confusión puesto que recoge los conflictos que se presentan entre categorías. Se trata de una matriz bidimensional, en donde las filas se ocupan por las clases de referencia, y las columnas por las categorías deducidas de la

clasificación. Lógicamente ambas tendrán el mismo número y significado; se trata, en suma, de una matriz cuadrada: $n \times n$, en donde n indica el número de categorías.

La diagonal de esta matriz expresa el número de puntos de verificación en donde se produce acuerdo entre las dos fuentes (mapa y realidad), mientras los marginales suponen errores de asignación. La relación entre el número de puntos correctamente asignados y el total expresa la fiabilidad global del mapa. Los residuales en filas indican tipos de cubierta real que no se incluyeron en el mapa, mientras los residuales en columnas implican cubiertas del mapa que no se ajustan a la realidad. Representan los errores por omisión y de comisión, respectivamente.

El interés de estas tablas de confusión procede de su capacidad para plasmar los conflictos entre categorías. De esta forma, no solamente se conoce la fiabilidad de la asignación en general, sino también la fiabilidad para cada una de las clases y las principales confusiones entre ellas.

A partir de la matriz de confusión pueden desarrollarse toda una serie de medidas estadísticas que concluyan el proceso de validación. La más simple consiste en calcular la fiabilidad global del mapa, relacionando los elementos de la diagonal con el total de puntos muestreados:

$$F_m = \frac{\sum X_i}{\sum \sum X_{ij}} \quad [6.2]$$

donde el término del numerador representa la sumatoria de los valores en la diagonal, y el del denominador el número total de píxeles tomados en cuenta en la muestra. Ahora bien, este valor constituye únicamente una estimación basada sobre la muestra. De acuerdo con la teoría del muestreo, pueden calcularse los umbrales inferior y superior en los que se encontraría la exactitud real alcanzada por el mapa. Ese intervalo se calcula, para un determinado nivel de significación (α), a partir del error del muestreo (ES) y del nivel de probabilidad ($1 - \alpha$):

$$F = F_m \pm z ES \quad [6.3]$$

donde z indica la abscisa del área bajo la curva normal para ese nivel de probabilidad ($1 - \alpha$); ES es el error estándar del muestreo, en función del porcentaje de aciertos (p), de fallos (q) y del tamaño de la muestra (n):

$$ES = \frac{\sqrt{p q}}{n} \quad [6.4]$$

Ahora bien, conviene tener en cuenta que este valor puede ocultar importantes diferencias entre categorías. Por ello, un análisis más riguroso debe también considerar las celdillas marginales de la matriz. En el caso de las filas, los marginales indican el número de píxeles que perteneciendo a una determinada categoría, no fueron incluidos en ella. Estos se denominan errores de omisión (E_o). Para cada clase se calculan como:

$$E_{ii} = \frac{X_{i.} - X_{ii}}{X_{i.}} \quad [6.5]$$

donde $X_{i.}$ indica el marginal de la fila i , y X_{ii} la diagonal de dicha fila.

De igual forma, las celdillas no diagonales de las columnas expresan los errores de comisión (E_c); esto es, píxeles que se incluyeron en una determinada categoría perteneciendo realmente a otra:

$$E_{.i} = \frac{X_{.i} - X_{ii}}{X_{.i}} \quad [6.6]$$

donde $X_{.i}$ indica el marginal de la columna i , y X_{ii} la diagonal de dicha columna.

También resulta de gran interés analizar las relaciones múltiples entre las distintas categorías. Con este objetivo, se han introducido en los últimos años las técnicas de análisis categórico multivariante, idóneas para el estudio global de matrices de confusión (Congalton, 1991).

Uno de los índices más empleados, en este sentido, es el estadístico Kappa (κ), que mide la diferencia entre el acuerdo mapa-realidad observado y el que cabría esperar simplemente por azar. En definitiva, intenta delimitar el grado de ajuste debido sólo a la exactitud de la clasificación, prescindiendo del causado por factores aleatorios. La estimación de κ se obtiene a partir de la siguiente fórmula:

$$\kappa = \frac{N \sum X_{ii} - \sum X_{i.} X_{.i}}{N^2 - \sum X_{i.} X_{.i}} \quad [6.7]$$

en donde N indica el total de observaciones, X_{ii} indica el acuerdo observado, y $X_{i.}$ $X_{.i}$ (producto de marginales) el acuerdo esperado. El acuerdo observado aparece en la diagonal de la matriz, mientras el esperado nos sirve para calcular el ajuste entre mapa y realidad que puede deberse al azar. La estimación de κ sirve para conocer el grado de significación de este estadístico, y, por tanto, si el acuerdo observado se aleja o no significativamente del acuerdo esperado al azar. En definitiva, la prueba pretende evaluar si la clasificación ha discriminado las categorías de interés con precisión significativamente mayor a la que se hubiera obtenido con una asignación aleatoria.

Un valor de κ próximo a 1 indica un acuerdo pleno entre la realidad y el mapa, mientras un valor cercano a 0 sugiere que el acuerdo observado es puramente debido al azar. Por su parte un valor negativo, supone también una clasificación pobre, si bien su sentido depende de otros factores externos, como el propio tamaño de la muestra.

6.2 Evaluación de la aplicación práctica

Desafortunadamente, para realizar la evaluación de los mapas de uso de suelo obtenidos para la zona oeste de Guadalajara, no se contó con mapas extras para poder realizar una evaluación objetiva.

Solamente se contó con un mapa obtenido de la página en Internet del INEGI, el cual tiene una calidad baja y no cuenta con una clasificación muy detallada (Fig. 6.3). Sin embargo, haciendo un simple análisis visual se puede notar que en general la clasificación de las áreas urbanas y agrícolas es acertada; tomando como punto de referencia la zona urbana de Guadalajara por sí misma y las vías de comunicación más importantes que se distinguen en los mapas obtenidos, las cuales se ven en estos como líneas más o menos continuas de zona urbana. Por otro lado, se alcanza a observar una confusión entre las áreas de vegetación y de bosque. Esto se debe a que, probablemente se confundieron las firmas espectrales, y en lugar de haber unido los dos tipos de vegetación obtenidos originalmente, se debió haber unido la categoría de Vegetación I con la de bosque, para así poder obtener una clasificación más cercana a la del mapa de referencia. También se observa que si bien se acercan las zonas definidas en el mapa y las obtenidas de la clasificación, estas aparecen mucho más mezcladas en las imágenes que se obtuvieron en este trabajo. Esto se debe principalmente a que el mapa que se toma de referencia no tiene un grado de detalle muy bueno, y a que probablemente las fechas de los mapas no coinciden (esto no se puede asegurar, puesto que en el sitio de Internet no se especifica a que fecha corresponde el mapa que se facilita). A pesar de esta falta de información, este mapa nos permite ver que la clasificación obtenida no se aleja de la realidad.



TESIS CON
FALLA DE ORIGEN

Fig. 6.3 Mapa de referencia obtenido a partir del sitio en Internet del INEGI. En este mapa se observan en color amarillo y delimitadas por una línea negra, las zonas urbanas; en verde la zona de bosque; en café la vegetación secundaria; en azul claro las zonas agrícolas; azul las zonas de agua; y en amarillo sin delimitar los pastizales.

A pesar de que no se contó con un mapa fidedigno con el cual evaluar la fiabilidad de la clasificación, se decidió realizar el análisis anteriormente descrito a partir de los campos de entrenamiento (Fig. 5.18). Es decir, en lugar de realizar un muestreo aplicable a un mapa de referencia fidedigno, se tomaron las mismas zonas de entrenamiento como si se trataran del muestreo, para comparar éstas con los mapas obtenidos con las distintas técnicas de clasificación.

Si bien esta evaluación no puede ser tomada como una medida fiable de la correspondencia entre los mapas de uso de suelo y la realidad, sí se puede tomar en cuenta como medida objetiva de comparación del comportamiento de cada método al realizar la clasificación.

Los resultados de su matriz de confusión y las estadísticas antes descritas (error por omisión, comisión, intervalo de confianza y κ) de las técnicas por máxima verosimilitud, filtro modal posclasificación y filtro mediano preclasificación se muestran en las tablas 1, 2 y 3 respectivamente.

En primer lugar se puede observar que las clasificaciones en todos los casos son bastante buenas, pues los errores por comisión y por omisión son muy pequeños. Esto, a pesar de que era de esperarse (pues estamos ocupando los campos de entrenamiento como referencia), nos demuestra que las firmas espectrales están, desde este punto de vista, bien definidas, además de que las tres técnicas tienden a clasificar de manera muy similar las imágenes.

Comparando el desempeño de las tres técnicas, es notable que el del filtro modal es casi perfecto, pues los errores por comisión y omisión son casi cero. En segundo lugar se encuentra el del filtro mediano, y por último el de máxima verosimilitud.

Tomando en cuenta κ , que como ya se vió es la medida más confiable para comparar métodos y trabajos distintos, se tiene que los valores de κ son de 0.9944, 0.9994, y 0.9990 para las técnicas de máxima verosimilitud, filtro modal y filtro mediano respectivamente. Si bien todos los valores son muy altos, y en este caso no representan la exactitud con la cual representan la realidad los mapas, si nos sirven para medir, de una forma más objetiva, el desempeño de las técnicas de clasificación por sí mismas. Gracias a estos valores se corrobora lo que ya se había notado anteriormente, que el desempeño de la técnica de filtrado posclasificación con un filtro modal es superior a la técnica de máxima verosimilitud por sí sola, y ligeramente superior a la técnica de filtrado preclasificación con un filtro mediano.

Por la misma naturaleza del análisis, éste es muy sesgado al analizar las matrices de confusión. Sin embargo, se observa que para el método de máxima verosimilitud las principales confusiones se dan entre ambos tipos de agricultura y las zonas urbanas, entre vegetación y bosque, entre suelo y zonas agrícolas, y en general las zonas urbanas tienden a confundirse con otras cubiertas. En las técnicas de clasificación por contexto, estas confusiones se reducen bastante, eliminándose por completo las confusiones entre vegetación y bosque. Para el caso de la posclasificación, se conserva solamente la confusión entre zona agrícola de riego y la zona urbana (algo que es muy común sobre todo en áreas urbanas de baja densidad, debido a la abundancia de áreas verdes que estas presentan). Para el caso de la preclasificación se conservan solamente las confusiones entre zonas agrícolas con zonas

urbanas y de suelo desnudo. Esto se puede explicar debido a la época del año en que se adquirió la imagen, pues durante ésta las zonas de cultivo de temporal no presentan vegetación y son fácilmente confundibles con suelo desnudo o bien con área urbana. La confusión entre las zonas de vegetación y bosque se puede explicar debido a la misma naturaleza de la vegetación en esta zona, pues en ambos casos es muy escasa y en muchos lugares existe un traslapo entre éstas.

Tabla 6.1 Análisis de la matriz de confusión para la técnica de clasificación de máxima verosimilitud tomando como referencia el campo de entrenamiento.

	1	2	3	4	5	
1	1249	0	0	0	0	0.0024
2	0	2033	0	0	3	0.0083
3	0	0	2744	3	5	0.0029
4	0	0	3	305	0	0.0097
5	0	0	0	0	1225	0.0000
6	2	11	2	0	0	0.0051
Total	1251	2044	2749	308	1233	
ErrorO	0.0016	0.0054	0.0018	0.0097	0.0065	

	6	Total	ErrorC
1	3	1252	0.0024
2	14	2050	0.0083
3	0	2752	0.0029
4	0	308	0.0097
5	0	1225	0.0000
6	2898	2913	0.0051
Total	2915	10500	
ErrorO	0.0058		0.0044

ErrorO = Errors of Omission (expressed as proportions)
 ErrorC = Errors of Commission (expressed as proportions)

90% Confidence Interval = 0.0011 (0.0033 - 0.0054)
 95% Confidence Interval = 0.0013 (0.0031 - 0.0056)
 99% Confidence Interval = 0.0017 (0.0027 - 0.0060)

KAPPA INDEX OF AGREEMENT (KIA)

Overall Kappa = 0.9944

TESIS CON
 FALLA DE ORIGEN

Tabla 6.2 Análisis de la matriz de confusión para la técnica de clasificación por contexto (filtro modal posclasificación) tomando como referencia el campo de entrenamiento.

	1	2	3	4	5	
1	1251	0	0	0	0	0.0000
2	0	2044	0	0	0	0.0024
3	0	0	2749	0	0	0.0000
4	0	0	0	308	0	0.0000
5	0	0	0	0	1233	0.0000
6	0	0	0	0	0	0.0000
Total	1251	2044	2749	308	1233	
ErrorO	0.0000	0.0000	0.0000	0.0000	0.0000	

	6	Total	ErrorC
1	0	1251	0.0000
2	5	2049	0.0024
3	0	2749	0.0000
4	0	308	0.0000
5	0	1233	0.0000
6	2910	2910	0.0000
Total	2915	10500	
ErrorO	0.0017		0.0005

ErrorO = Errors of Omission (expressed as proportions)
 ErrorC = Errors of Commission (expressed as proportions)

90% Confidence Interval = 0.0004 (0.0001 - 0.0008)
 95% Confidence Interval = 0.0004 (0.0001 - 0.0009)
 99% Confidence Interval = 0.0005 (0.0000 - 0.0010)

KAPPA INDEX OF AGREEMENT (KIA)

Overall Kappa = 0.9994

TESIS
 FALLA DE ORIGEN

Tabla 6.3 Análisis de la matriz de confusión para la técnica de clasificación por contexto (filtro mediano preclasificación) tomando como referencia el campo de entrenamiento.

	1	2	3	4	5	
1	1251	0	0	0	1	0.0008
2	0	2043	0	0	1	0.0029
3	0	0	2749	0	0	0.0000
4	0	0	0	308	0	0.0000
5	0	0	0	0	1231	0.0000
6	0	1	0	0	0	0.0003
Total	1251	2044	2749	308	1233	
ErrorO	0.0000	0.0005	0.0000	0.0000	0.0016	

	6	Total	ErrorC
1	0	1252	0.0008
2	5	2049	0.0029
3	0	2749	0.0000
4	0	308	0.0000
5	0	1231	0.0000
6	2910	2911	0.0003
Total	2915	10500	
ErrorO	0.0017		0.0008

ErrorO = Errors of Omission (expressed as proportions)
 ErrorC = Errors of Commission (expressed as proportions)

90% Confidence Interval = 0.0004 (0.0003 - 0.0012)
 95% Confidence Interval = 0.0005 (0.0002 - 0.0013)
 99% Confidence Interval = 0.0007 (0.0001 - 0.0015)

KAPPA INDEX OF AGREEMENT (KIA)

Overall Kappa = 0.9990

TESIS CON
FALLA DE ORIGEN

7. CONCLUSIONES

Gracias a la realización del presente trabajo de tesis pude llegar a la conclusión de que, es bastante importante contar con bases teóricas sólidas para entender un problema en particular. El desarrollo de la aplicación práctica, o inclusive la presentación de las metodologías de clasificación de imágenes multispectrales, no se hubiera llevado a buen fin si antes no se hubieran tratado los fundamentos teóricos con el debido grado de profundidad. Considero que este grado de profundidad es óptimo en este trabajo, puesto que se abarca la amplitud de temas que están involucrados en la clasificación de imágenes multispectrales obtenidas por Percepción Remota; tratando cada tema en particular de una forma clara y concisa, sin profundizar demasiado, pero dando la información necesaria para entender claramente los conceptos.

Como resultado de la forma en que se abordó el tema, este documento de tesis es, por sí mismo, una guía para la gente interesada en la clasificación de imágenes multispectrales. Ya sea una persona que se está iniciando en el tema, o alguien que cuenta ya con ciertos conocimientos. En este sentido, esta guía está dirigida principalmente a gente del área de cómputo, pues se intentó en todo momento adecuar los términos propios del tema, a la terminología usada en el área de computación. Del mismo modo se hizo énfasis en las particularidades que son de más interés en el área de computación, como lo es el procesamiento digital de imágenes, pero sin dejar nunca a un lado el contexto de la aplicación práctica.

En relación con la aplicación práctica, considero ésta de una gran utilidad, no sólo porque por sí misma arroja resultados, si no también como instrumento pedagógico. La presentación de ésta, después de una presentación de información principalmente teórica, da como resultado un entendimiento más claro de las técnicas, procesos y metodologías presentadas con anterioridad. Esto permite prevenir que temas de vital importancia en un caso práctico queden minimizados, al parecer estos no muy importantes en su planteamiento teórico. Como ejemplo se puede mencionar el caso particular de la importancia de la definición y desarrollo de los campos de entrenamiento, lo cual puede parecer a simple vista algo trivial, pero que es de vital importancia en la exactitud de los resultados.

Considero que una de las principales aportaciones de este trabajo es, la propuesta de una metodología sencilla y flexible, pero a la vez sólida, para la clasificación de imágenes multispectrales. La presentación de esta metodología permite tener una guía concisa para abordar de una forma más directa, sencilla y eficiente un problema real de clasificación temática. Esta propuesta está enfocada a resolver problemas en los cuales se involucren áreas no muy homogéneas, que presenten el efecto de sal y pimienta, puesto que involucra las técnicas de clasificación por contexto para mejorar los resultados en áreas de estas características. Esta metodología está enfocada a gente del área de computación; puesto que la obtención del mapa temático final es en gran medida independiente de contar con grandes conocimientos acerca del área en particular o con una gran experiencia en el análisis de imágenes para la obtención de mapas de uso de suelo. Esto permite obtener resultados sin necesidad de especializarse demasiado en el tema, algo que puede ser muy interesante para alguien que le interesa más el método en sí mismo y no tanto el resultado final.

Por otro lado, no ha de tomarse lo anterior como un desprecio total a la medida o evaluación de la fiabilidad del mapa temático final. Por el contrario, en este trabajo se toma como prioridad el poder medir, de una forma objetiva, la efectividad de las metodologías probadas.

En este sentido, desgraciadamente no se pudieron evaluar cabalmente las tres técnicas que se probaron prácticamente. Esto debido a la falta de material adicional que permitiera tener un punto de referencia lo bastante fiable como para considerar la evaluación como válida. Sin embargo, el intento de evaluación que se hizo, si bien no es lo suficientemente objetivo, da como resultado una medida del desempeño de las técnicas de clasificación mucho más objetiva que un simple análisis visual.

Como resultado de la evaluación, se puede concluir que en la clasificación de imágenes multiespectrales que involucran áreas heterogéneas como áreas urbanas, la técnica que mejores resultados proporciona es la de clasificación por contexto usando un filtro modal en la posclasificación. Si bien esto corrobora lo presentado en muchos artículos previamente presentados, es muy importante probar la aplicación de esta técnica en un área de nuestro país.

Aunado a la evaluación objetiva de las técnicas de clasificación, se tiene que la aplicación del filtro modal no implica un esfuerzo extra muy grande, pues es bastante sencilla su aplicación y los beneficios que se obtienen superan con creces el esfuerzo extra invertido.

En conclusión, la decisión de presentar la metodología propuesta basándose en esta técnica, resulta más que acertada, puesto que aparte de las bondades de la metodología, ya mencionadas en su momento, se corrobora que es la más eficaz en exactitud de clasificación y en la presentación de resultados.

A modo de comentario, cabe destacar que el mapa de uso de suelo es muy bueno, considerando que el análisis lo hizo una persona que no cuenta con gran experiencia en el tema. Aunque los resultados de la clasificación no coinciden por completo con la poca información que se pudo conseguir para tomarla como punto de referencia confiable. Esto puede llamar la atención a personas dedicadas a este tema, pues implica que una persona con mejor experiencia podría obtener resultados mucho mejores.

BIBLIOGRAFÍA CONSULTADA Y REFERENCIAS

1. Campbell, J. B., 1987. Introduction to Remote Sensing. New York, The Guilford Press.
2. Chuvieco, E., 1990, Fundamentos de Teledetección Espacial. Madrid, Ediciones Rialp.
3. Congalton, R. G., 1991, A review of Assessing the Accuracy of Classifications of Remotely Sensed Data. Remote Sens. Environ. pp. 35-46.
4. Congalton, R. G., 1988, A comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sense data. "Photogrammetric Engineering and Remote Sensing", Vol. 54, pp. 593-600.
5. Cosentino, M. J., C. E. Woodcock y J. Franklin. 1981. Scene analysis for wildland fire-fuel characteristics in a Mediterranean climate. Proc. 15th Intern. Symp. on Remote Sensing of Environment, Ann Arbor, pp. 635-646.
6. Cushman, J. L., 1987. The interactive effect of spatial resolution and degree of internal variability within land-cover types on classification accuracies. "International Journal of Remote Sensing", Vol. 8, pp. 15-29.
7. Danjoy, W. A. y F. G. Sadowski, 1978, Use of Landsat in the study of forest classification in the tropical jungle. Proc. 12th Intern. Symp. Rem. Sens. of Environment, Ann Arbor, pp. 947-951.
8. Duda, R. D. y P. E. Hart, 1973, Pattern Classification and Scene Analysis. New York, John Wiley & Sons.
9. Eastman, J. R., 1993, IDRISI. Student Manual, Version 4.1. Clark University Graduate School of Geography Worcester, Massachusetts.
10. Fernández de la Vega, R., R. M. Prol-Ledesma y G. Orozco, 2001, Hydrothermal alteration and main structures mapping using TM images in La Primavera geothermal field (Mexico). Geofísica Internacional. Vol. 40, Núm. 3, pp. 147-162.
11. Gordon, D. K. y R. Philipson, 1986, A texture-enhancement procedure for separating orchard from forest in Thematic Mapper data. "International Journal of Remote Sensing", Vol. 7, pp. 301-304.
12. Hay, A. M., 1979, Sampling designs to test land-use map accuracy. "Photogrammetric Engineering and Remote Sensing", Vol. 45, pp. 529-533.
13. Hoffer, R. M. y P. H. Swain, 1980, Computer processing of satellite data for assessing agricultures, forest, and rangeland resources. Proc. 14th Intern. Soc of Photog., Hamburg, pp. 437-446.
14. Huete, A. R., 1987, Spectral signatures and vegetation indices. II Reunión Nac. Del Grupo de Trabajo en Teledetección, Valencia, pp. 13-26.
15. Jensen, J. R., 1996, Introductory Digital Image Processing A remote Sensing Perspective, 2nd Ed., Upper Sadle River, N.J.
16. Ketting, R. L. y D. A. Ladgrebe, 1975, Classification of multispectral image data by extraction and classification of homogeneous objects. Proc. Symposium on Machine Classification of Remotely Sensed Data, Purdue, pp. 1-11.
17. Lillesand, T. M. y R. W. Kiefer, 1987, Remote Sensing and Image Interpretation, 2nd Ed., New York, John Wiley & Sons.
18. Markham, G. L. y J. R. G. Townshend, 1981, Land cover classification accuracy as a function of sensor spatial resolution. Proc 15th Intern. Symp. Rem. Sens. of Environment, Ann Arbor, pp. 1075-1090.

19. Meliá, J, 1986, Signaturas Espectrales e Índices de Vegetación, Burjassot, Facultad de Ciencias Físicas U. Valencia.
20. Meliá, J., S. Gandía y V. Caselles, 1986, Teledetección y signaturas espectrales, "Revista de la Real Academia de Ciencias Exactas, Físicas y Naturales", Vol. 80.
21. OTA, 1984, Remote Sensing and the Private Sector: Issues for Discussion. A Technical Memorandum, Washington, D.C., U.S. Congress, Office of Technology Assessment.
22. Richards, J. A., 1993, Remote Sensing Digital Image Analysis. An Introduction, 2nd Ed., Berlín, Springer-Verlag.
23. Schowengerdt, R. A., 1983, Techniques for Image Processing and Classification in Remote Sensing, New York, Academic Press.
24. Schowengerdt, R. A., 1997, Remote Sensing Models and methods for image processing, 2nd Ed., San Diego, Academic Press.
25. Strahler, A. H. y T. L. Logan, 1978, Improving forest cover classification accuracy from Landsat by incorporating topographic information, Proc. 12th Intern. Symp. Rem. Sens. of Environment, Ann Arbor, pp. 927-942.
26. Stuckens, J., P.R. Coppin y M. E. Bauer, 2000, Integrating Contextual Information with per-Pixel Classification for Improved Land Cover Classification, Remote Sens. Environ, pp. 282-296
27. Swain, P.H. y S. M. Davis, Eds., 1987, Remote Sensing: The Quantitative Approach, New York, MacGraw-Hill.
28. Thomas, I. L., 1980, Spatial post-processing of spectrally-classified Landsat data, "Photogrammetric Engineering and Remote Sensing", Vol. 46, pp. 1201-1206.
29. Wagner, H. L. y G. H. Suits, 1983, A low cost classification algorithm for developing countries, en User's Guide to RIPS, Washington, Apéndice B, pp. 1525-1529.

Direcciones de URL:

1. <http://www.inegi.gob.mx> (Sistema Integral de información Geográfica y Estadística).
2. <http://www.elsevier.com.br>
3. <http://www.dgbiblio.unam.mx/>

APÉNDICE 1. CORRECCIÓN ATMOSFÉRICA

La radiación electromagnética se ve notablemente afectada por los distintos componentes de la atmósfera. La presencia de aerosoles y vapor de agua dispersa de una forma selectiva la radiación transmitida entre la superficie terrestre y el sensor. Por ello, la radiancia finalmente detectada por éste no corresponde exactamente a la que parte de la superficie terrestre, sino que cuenta con un porcentaje añadido, como consecuencia del efecto dispersor de la atmósfera.

El principal problema que implica esta dispersión es su carácter heterogéneo, en el espacio y en el tiempo. En otras palabras, la dispersión atmosférica no es constante en la imagen sino, que determinadas zonas pueden haber sido más afectadas que otras, en función de la presencia de diversos aerosoles o vapor de agua. Además, el efecto es dependiente de la longitud de onda, y varía entre imágenes de forma difícil de predecir. Desgraciadamente, resulta muy complejo abordar una corrección rigurosa de la dispersión atmosférica, por cuanto requiere una serie de medidas simultáneas a la adquisición de la imagen.

Pese a estas dificultades, es preciso realizar, al menos, una estimación del efecto atmosférico. Esta corrección será muy interesante en tres tipos de situaciones: (i) cuando pretendan realizarse combinaciones lineales entre bandas, puesto que el efecto de dispersión es distinto en función de la longitud de onda; (ii) cuando intenten establecerse modelos que pongan en relación los niveles de brillantez con determinados parámetros físicos: temperatura, humedad del suelo, etc., y (iii) cuando se realicen estudios multi-temporales, puesto que la dispersión sufrida por una imagen no es comparable a la que experimenta otra adquirida en distinta fecha.

Entre los métodos propuestos para corregir el aporte de radiancia atmosférica, se encuentra el del histograma por sus valores mínimos (*Histogram Minimum Method, HMM*). Se asume que las áreas cubiertas con materiales de fuerte absorbanza (agua, zonas en sombra), deberían presentar una radiancia espectral muy próxima a cero. En la práctica, el histograma de los valores de brillantez de la imagen siempre presenta un mínimo superior a ese valor, que se atribuye al efecto de dispersión atmosférica. En consecuencia, una aproximación sencilla a la corrección atmosférica consiste en restar a todos los niveles de brillantez (ND) de banda el ND mínimo de esa misma banda, situando el origen del histograma en cero:

$$ND_{i,j,k}' = ND_{i,j,k} - ND_{min,k}$$

esto es, el ND del píxel (i,j) en la banda k , se ajusta restándole el ND mínimo de esa misma banda.