

PRÁCTICO 11

TRANSFORMACIONES DE LA IMAGEN: CLASIFICACIONES SUPERVISADAS Y NO SUPERVISADAS

Objetivos

- Adquirir experiencia para clasificar imágenes digitales
- Adquirir experiencias en el manejo de software Erdas Imagine 8.4
- Realizar Análisis de Componentes Principales.
- Realizar filtrados permanentes en la imagen
- Calculo de Índices de Vegetación

Material necesario

Imágenes provenientes del sensor TM de LANDSAT, Imágenes SPOT o imágenes NOAA, Software Erdas 8.4

Introducción

Hay muchos procesos realizados digitalmente a las imágenes, que escapan a la generalidad que se pretende dar a esta Guía de Trabajos Prácticos, mencionaremos algunos de los más comunes.

Clasificar una imagen es tomar decisiones, reemplazando interpretaciones vagas y ambiguas por un proceso más cuantitativo y repetible. A través de una clasificación puede hacerse un mapeo eficiente y consistente de grandes áreas de la superficie terrestre.

Al clasificar una imagen se asigna cada píxel a una categoría, que representan una gama de variedad dentro de la imagen. Se puede clasificar en forma automática o no supervisada, o señalarle al programa “píxeles semilla” característicos de la clase que se pretende seleccionar, logrando así una clasificación supervisada.

El producto final en cualquiera de los dos casos es un mapa con la cantidad de clases que se desee (puede ser una clasificación de vegetación, de áreas ecológicas, etc.) que siempre es necesario chequear a campo.

Clasificación de imágenes

Se incluyen en este tema aquellas 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, ya sea ésta visual o digital. Obviamente, tales operaciones no proporcionan una nueva transformación que no estuviera ya incluida en los datos originales. Permiten, no obstante, mejorar la disposición de los datos, de forma que sean mas evidentes determinados fenómenos de interés.



Figura 11-1

Filtros estadísticos y sus efectos

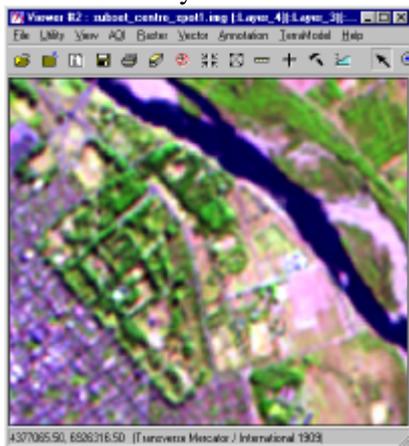
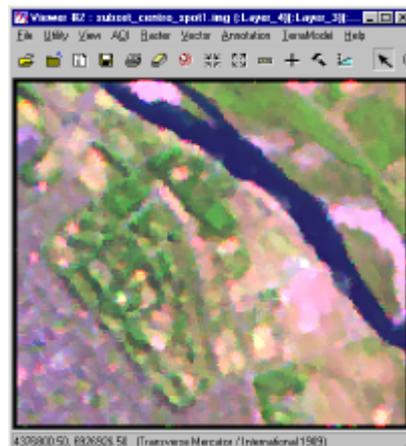
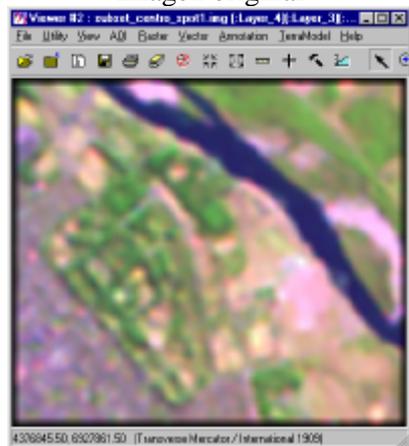


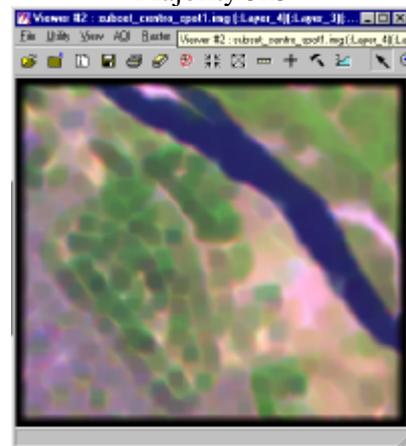
Imagen original



Majority 5x5



Mean 5x5

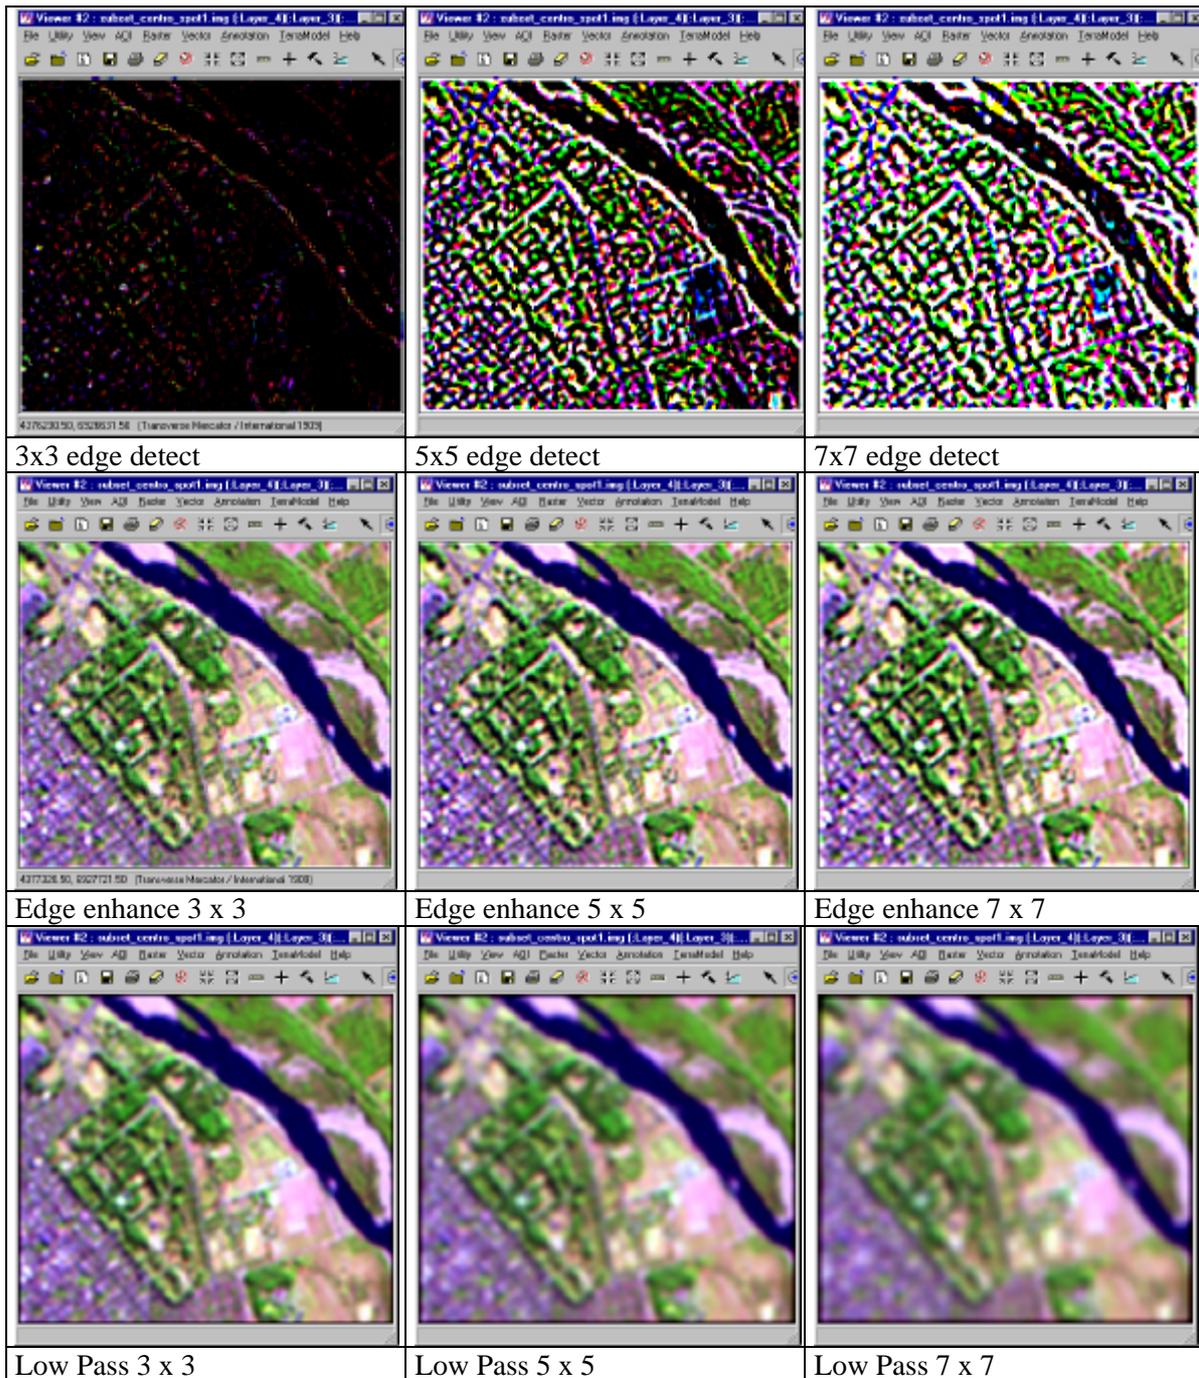


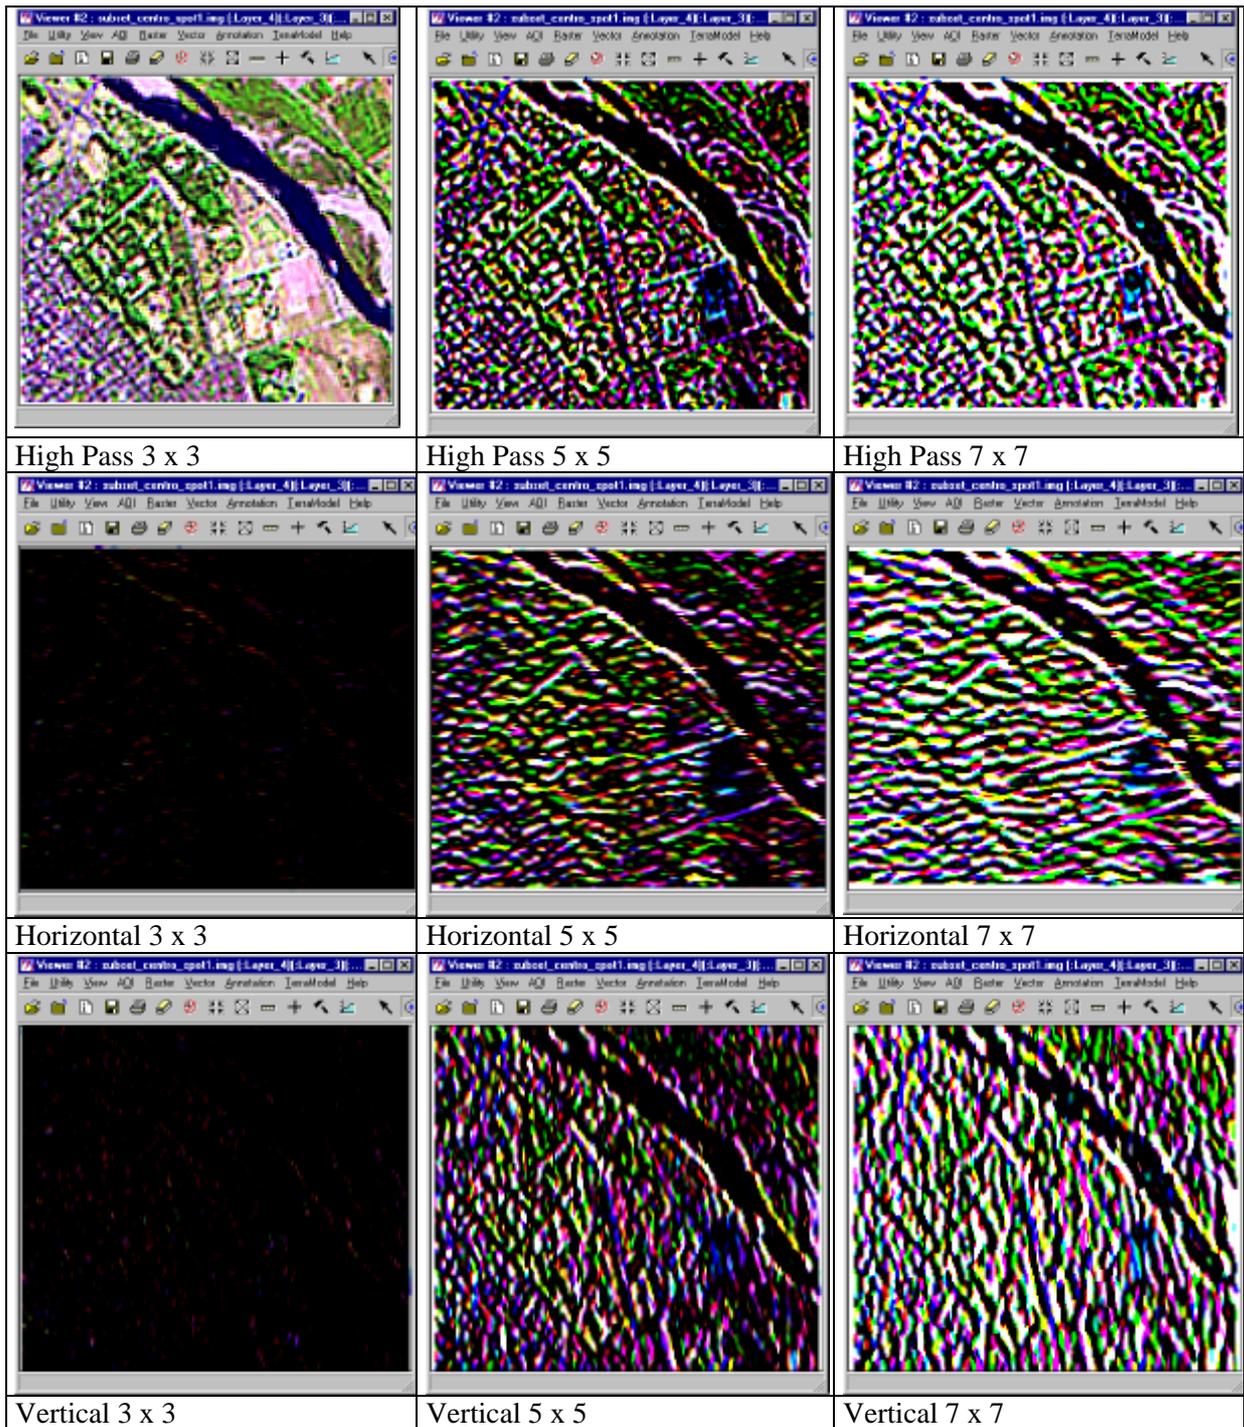
Min 5x5

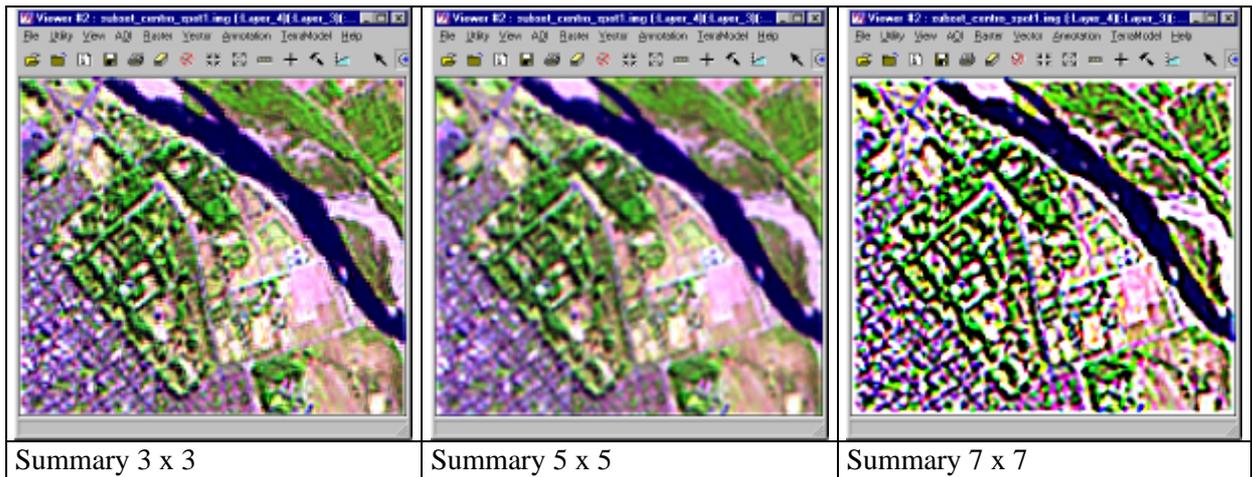
Figura 11-2

Las operaciones de filtrado aplicados sobre una imagen suavizan o refuerzan los contrastes presentes. Es una transformación de los datos digitales originales, para que se asemejen o se diferencien más de los píxeles vecinos.

También tenemos operaciones dirigidas a crear bandas artificiales a partir de combinaciones entre las bandas originales, con el fin de mejorar la discriminación de algunos aspectos temáticos dentro de la imagen, esas nuevas bandas se crean por combinación lineal de las originales: sumas ponderadas, multiplicaciones o divisiones, son las mas habituales. Para acotar nuestro comentario, nos ceñiremos a aquellas transformaciones que cuentan con una mayor tradición en aplicaciones medio ambientales de la teledetección espacial.







Cocientes e índices de vegetación

Se realiza un cociente píxel a píxel entre los valores almacenados en distintas bandas. Por ejemplo trabajando con las imágenes LANDSAT TM se combinan las bandas 4 y 3 (4/3), lográndose un buen contraste entre la vegetación sana y los suelos desnudos o poco cubiertos y la vegetación enferma. Cuanto mayor sea el contraste entre ambas bandas, mayor vigor vegetal presenta la cubierta observada. Bajos valores de contraste implican vegetación enferma o senescente, hasta llegar a las coberturas sin vegetación, que ofrecen un contraste muy pequeño.

Otros ejemplos de índices simples (Banda X - Banda Y)

o mas complejos
$$\frac{\text{Band X} - \text{Band Y}}{\text{Band X} + \text{Band Y}}$$

- Los índices son usados extensamente en exploración minera y análisis de vegetación para mostrar las diferencias entre varios tipos de roca o clases de vegetación. En muchos casos si son bien elegidos los índices pueden resaltar y discriminar diferencias que no pueden ser observadas al desplegar las bandas con datos originales
- También pueden ser usados para minimizar los efectos de sombras en imágenes multispectrales da satélite o aéreas. Pueden generarse imágenes blanco y negro de índices individuales o combinaciones de colores de 3 cocientes.
- Ciertas combinaciones de cocientes de imágenes Landsat TM son utilizadas por geologistas para interpretación por tipo de minerales. Por ejemplo Rojo 5/7, verde 5/4, azul 3/1.

Los siguientes índices son ejemplos preprogramados en ERDAS IMAGINE

- IR/R (infrared/red)
- SQRT (IR/R)
- Vegetation Index = IR-R
- Normalized Difference Vegetation Index (NDVI) = $\frac{IR - R}{IR + R}$
- Transformed NDVI (TNDVI) $\sqrt{\frac{IR - R}{IR + R} + 0.5}$
- Iron Oxide = TM 3/1
- Clay Minerals = TM 5/7
- Ferrous Minerals = TM 5/4
- Mineral Composite = TM 5/7, 5/4, 3/1

Sensor	IR Band	R Band
Landsat MSS	7	5
SPOT XS	3	2
Landsat TM	4	3
NOAA AVHRR	2	1

Bandas IR según Sensor

- Hydrothermal Composite = TM 5/7, 3/1, 4/3

Su empleo se justifica en dos situaciones:

- Para mejorar la discriminación entre suelos y vegetación, y
- Para reducir el efecto del relieve (pendiente y orientación) en la caracterización espectral de distintas coberturas.

El empleo de los cocientes para discriminar masas de vegetales se deriva del peculiar comportamiento radiométrico de estas coberturas. Como se recordara, la signatura espectral característica de la vegetación sana muestra un claro contraste entre las bandas visibles y especialmente la banda roja (0,6 a 0,7 μm). Mientras en la región visible, los pigmentos de la hoja absorben la mayor parte de la luz que reciben (para realizar la función clorofílica), en el infrarrojo cercano (0,7 a 1,1 micrómetros. Mientras en la región visible, los pigmentos de la hoja absorben la mayor parte de la luz que reciben (para realizar la función clorofílica), en el infrarrojo cercano estas circunstancias son bastantes transparentes. Por esta razón, la vegetación sana ofrece baja reflectividad en la banda roja del espectro y alta en el infrarrojo cercano. El contraste con la vegetación enferma, y sobre todo con los suelos, es bastante evidente en estas dos bandas. Los suelos, poco cromáticos, ofrecen menor variación espectral a distintas longitudes de onda, apareciendo con una curva mucho mas plana. En definitiva, podemos enunciar, como principio general, que cuanto mayor sea el contraste entre los ND de la banda infrarroja y roja, mayor vigor vegetal presentara la cubierta observada. Bajos valores de contraste indican una vegetación enferma o senescente, hasta llegar a las coberturas sin vegetación, que ofrecen un contraste muy pequeño.

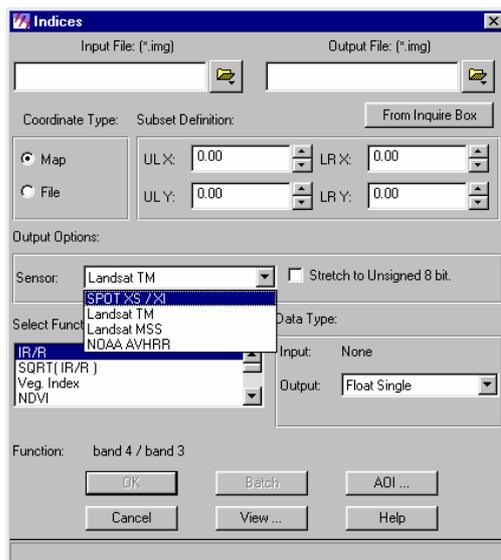


Figura 11-3: Cuadro de dialogo “indices” dentro de image interpreter

El cociente entre las bandas infrarroja y roja se ha empleado profusamente en estudios de cartografía y control de la vegetación. Para el caso del sensor MSS, ese cociente supone dividir las bandas 7 y 5; en el del TM, las bandas 4 3; para el HRV, la 3 y 2, y para el sensor AVHRR, los canales 2 y 1.

Respecto al NDVI, su empleo se ha impulsado recientemente para abordar estudios de pequeña escala, y principalmente para analizar cambios globales en la vegetación a partir del sensor AVHRR. Su principal ventaja, frente al cociente simple es su mas fácil interpretabilidad, ya que esta acotado entre (+ y - 1) con un umbral critico para coberturas vegetales en torno a 0,2. Este tipo de estudios permiten conocer el estado de vigor vegetal sobre grandes espacios, detectando fenómenos de amplios rangos de acción. Gracias a las características orbitales del satélite NOAA, este seguimiento puede realizarse casi en tiempo real, lo que permite abordar el control de episodios muy efímeros, así como la previsión de desastres.

Componentes principales

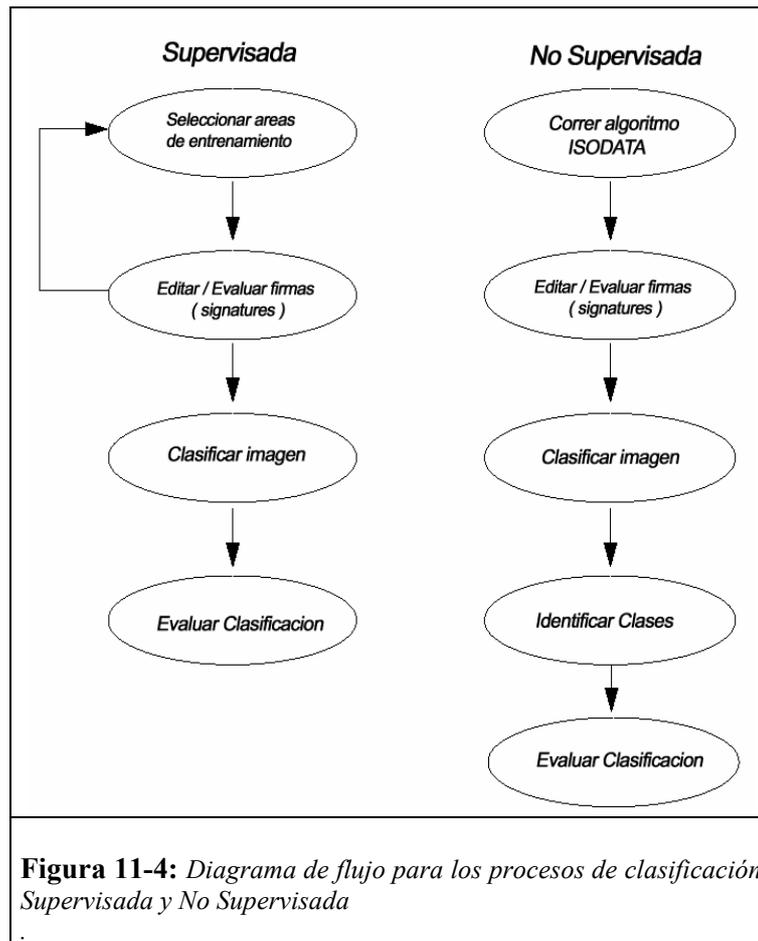
El análisis de Componentes Principales (ACP) es una técnica bastante empleada en ciencias sociales y naturales. Su objetivo es resumir un grupo amplio de variables en un nuevo conjunto, mas pequeño, sin perder una parte significativa. De la información original.

Esta capacidad de síntesis ha sido la basa de la aplicación del ACP en teledetección. La adquisición de imágenes sobre bandas adyacentes del espectro, implica con frecuencia detectar una 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 una o varias de ellas prácticamente irrelevantes. En este contexto, el ACP permite sintetizar (comprimir), las bandas originales, creando unas nuevas bandas, “los componentes principales de la imagen”, que recojan la

mayor parte de la información original. Esta síntesis resulta muy conveniente cuando se pretende abordar un análisis multitemporal, o cuando se intentan seleccionar las tres bandas mas adecuadas para una composición en color.

El ACP no resulta todavía muy popular entre los científicos del medio ambiente debido al tiempo de ordenador que requiere y a la destrucción de las relaciones entre la radiancia del objeto y valor digital. Por cuanto la transformación es dependiente de la escena, no pueden aplicarse reglas generales para la interpretación de los ACP, aunque algunos autores han mostrado el interés de esta técnica para realizar el análisis visual de composiciones coloreadas.

CLASIFICACIÓN DIGITAL



Conceptos previos

Para la mayor parte de los usuarios de la teledetección, la clasificación supone la fase culminante del tratamiento digital de imágenes. Hacia ella se orientan, casi siempre, las operaciones, puesto que los resultados de la clasificación marcan la calidad final del proyecto desarrollado.

Este papel protagonista viene dado por la misma naturaleza de la teledetección espacial. Los 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 un ordenador electrónico. Como fruto de la clasificación digital se obtiene una cartografía e inventario de las categorías objeto de estudio. La información multispectral se condensa, en definitiva, en un documento cartográfico y en unas

tablas estadísticas, que definen la localización y ofrecen el inventario superficial de las categorías de interés.

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 coberturas de interés, sin pretender que esa identificación sea extrapolable a otras situaciones.

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 (variable nominal o categórica), o bien intervalos de una misma categoría de interés (variable ordinal). Por Ej., 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.

Fase de entrenamiento

Para que una fotografía aérea pueda ser interpretada en detalle es preciso que exista una experiencia previa, que nos permita identificar cada una de las categorías de interés por una serie de rasgos, como son tono, textura, situación o tamaño. Es posible distinguir entre matorral y arbolado, gracias a que este tiene una textura más rugosa; mientras que la separación entre agua y cultivos herbáceos de secano se realiza sobre la diferencia de tonalidad. De la misma forma, la clasificación digital se inicia definiendo cada una de las categorías que pretenden discriminarse. Por cuanto se trata de una clasificación numérica; esto es, se trata de obtener el ND, o mejor aun 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 cobertura. 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.

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 representen, 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, en 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 incorrecta selección de ésta conducirá inexorablemente a pobres resultados en la clasificación posterior.

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado, de acuerdo a la forma en que son obtenidas las estadísticas de entrenamiento. 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 usuario, en este caso, la labor de encontrar correspondencias entre esos grupos y sus categorías de interés.

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” al ordenador 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.

MÉTODO NO SUPERVISADO

Este método se dirige 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 mas 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), mas 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 este “dar sentido” e interpretar, el significado temático de esas categorías espectrales.

El método para definir los agrupamientos espectrales es muy similar al empleado en otras técnicas de clasificación automática de datos.

Se basa en un triple proceso:

- selección de las variables que intervienen en el análisis.
- selección de un criterio para agrupar los casos similares.
- selección de un criterio para medir la similitud a distancia entre casos.

En nuestro contexto, las variables son las bandas espectrales seleccionadas para la clasificación, ya sean estas originales o fruto de alguna transformación. 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 nuestra leyenda.

En cuanto al algoritmo de agrupamiento, las opciones también son numerosas. Uno de los mas extendidos es el denominado ISODATA. En esencia, este algoritmo procede a partir de las siguientes fases:

Se señalan una serie de centros de clase, de acuerdo al numero y forma indicados por el usuario;

Se asignan todos los píxeles de la imagen al centro de clase mas próximo,

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.

Se vuelven a asignar todos los píxeles de la imagen al centro mas cercano, el cual debido al desplazamiento registrado en el primer paso, no tiene porque coincidir con la anterior asignación, vuelven a calcularse los centros de clase, teniendo en cuenta las nuevas incorporaciones.

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.

Proceso ISODATA

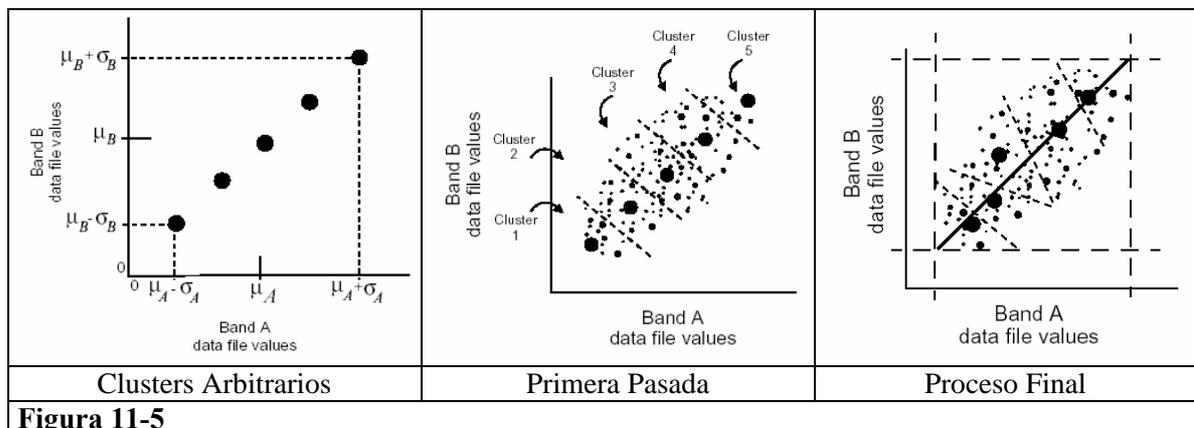


Figura 11-5

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.

Como en el caso del Método Supervisado, es necesario analizar los píxeles incluidos en cada grupo para obtener sus medidas estadísticas elementales: media, desviación típica, etc., que servirán para abordar la fase posterior de clasificación.

MÉTODO SUPERVISADO

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 o áreas de entrenamiento). El término indica que tales áreas sirven para “entrenar” al ordenador en el conocimiento de las distintas categorías.

En otras palabras, a partir de ellas el ordenador 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 equipos de tratamiento digital permiten localizar interactivamente los campos de entrenamiento. Con ayuda del digitalizador o ratón electrónico, el usuario introduce sobre la pantalla los vértices 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 la 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, el ordenador calcula las estadísticas elementales de cada categoría: media, rango, desviación típica, 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.

Fase de asignación

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, naturalmente, en función de los ND, para cada una de las bandas que intervienen en el proceso. Fruto de esta fase será una nueva imagen, cuyos ND expresen la categoría en la cual se ha incluido cada uno de los píxeles de la imagen original.

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

- **Mínima Distancia**, por el cual el píxel se asigna a la clase más cercana.
- **Paralelepípedos**, que permite señalar al usuario unos umbrales de dispersión asociados a cada clase.
- **Máxima Probabilidad**, en donde el píxel se asigna a aquella clase con la que posee mayor probabilidad de pertenencia.

Clasificador de mínima distancia

El criterio mas sencillo para asignar un píxel a una de las categorías consiste en incluirlo en la mas cercana; esto es, en aquella que minimice la distancia entre ese píxel y el de los valores correspondientes al centro 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.

Este algoritmo es bastante sencillo y rápido de ejecutar, y puede ofrecer buenos resultados cuando no se observe un gran solape entre categorías. Puesto que siempre existe una clase mas cercana, no deja lugar a píxeles sin clasificar, incluso aunque éstos se alejen notablemente del centro de clase.

Clasificador de paralelepípedos

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.

En suma, el píxel 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 típica, o con un múltiplo suyo.

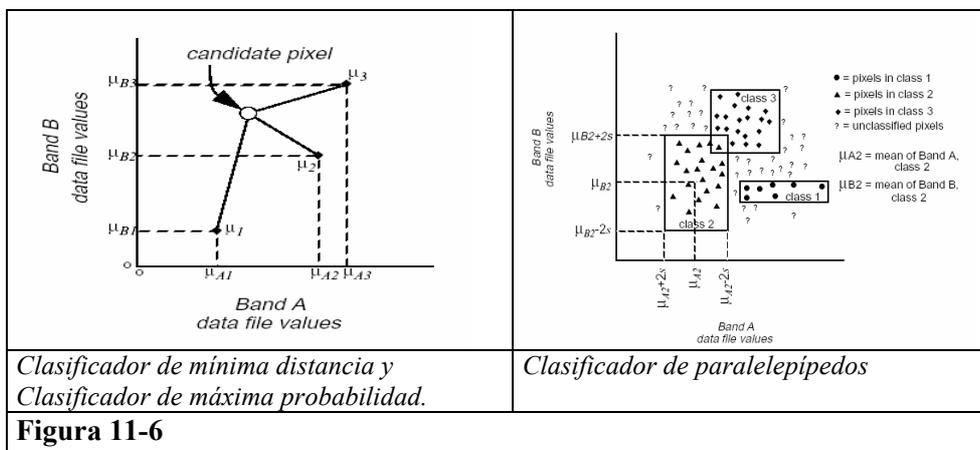
Este criterio de asignación tiende a delinear unos polígonos multidimensionales de lados Paralelos, de ahí su nombre.

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 mas categorías, y, por otro, que algunos píxeles queden sin clasificar.

Clasificador de máxima probabilidad

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 varianza-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 probabilidad es el mas complejo y el que demanda mayor volumen de cálculo. Sin embargo, es el mas empleado, por su robustez y por ajustarse con mas rigor a la disposición original de los datos.



Clasificación Multitemporal

La dimensión temporal puede resultar clave en la interpretación de imágenes, podemos dividir las aplicaciones multitemporales en dos grupos:

- Estudios multianuales, empeñados en la detección del cambio entre dos fechas de referencia.
- Estudios multiestacionales, en donde se utilizan imágenes de distintas fechas para enriquecer la información espectral, aportando un componente fenológico muy interesante en coberturas vegetales.

En lo que se refiere a estudios multianuales, la mayor parte de los trabajos de clasificación digital abordan cada imagen independientemente, para luego detectar los cambios por comparación de las clasificaciones obtenidas en las distintas fechas. Son menos frecuentes aquellos que clasifican, en conjunto, todas las bandas originales de las distintas fechas.

En los estudios multiestacionales es mucho más frecuente que se combinen dos o más imágenes, como paso previo a la clasificación. Varios autores han demostrado que este enfoque proporciona mejores resultados que el análisis mono-temporal. No obstante, también ofrece importantes problemas, por cuanto –si quieren combinarse píxel a píxel- es necesario que las imágenes presenten homogeneidad radiométrica y ajuste geométrico.

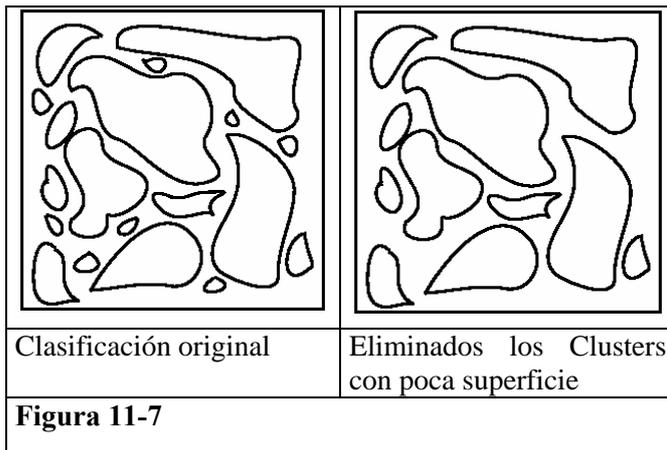
La exactitud geométrica resulta el factor más complejo. Se requiere que las imágenes a clasificar conjuntamente estén registradas con elevada precisión. De lo contrario, el clasificador estará considerando un ND que no es el propio del píxel que pretende asignar, sino de alguno de los vecinos, con lo que la exactitud final resulta seriamente comprometida. Normalmente, son necesarias ecuaciones de ajuste de segundo o tercer grado para lograr estos niveles de detalle, sobre la base de haber localizado con gran detalle los puntos de control.

En el caso de estudios con varias imágenes, suelen emplearse técnicas para sintetizar el conjunto de bandas originales en un menor número de variables. El empleo de componentes principales suele ser común en este contexto.

Suavización de los resultados

Resulta bastante frecuente que los resultados de una clasificación digital adolezcan de una excesiva fragmentación. En otras palabras, las diversas categorías se imbrican 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 dificultándose 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:

- Por un lado, a que la mayor parte de los criterios de asignación no tienen en cuenta la pertenencia de píxeles vecinos
- Por otro, a la propia complejidad del paisaje, directamente relacionada con la aparición de píxeles de borde –fronterizos a dos o más categorías- que son los principales responsables de la discontinuidad visible en el mapa.



Para solventar este problema, suele aplicarse una técnica de suavización de resultados, similar en la concepción, aunque no en la ejecución, a los filtros de paso bajo. Sobre la imagen clasificada no puede aplicarse un filtro convencional, puesto que cualquier promedio de píxeles vecinos introduciría cambios imprevisibles en la clasificación.

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 X 3 píxeles, si bien la técnica es independiente de su tamaño. En la terminología habitual se distinguen, a este respecto, dos tipos de filtro:

Filtro modal, en el cual, el píxel situado en el centro de la matriz se asigna a la categoría más frecuente entre los píxeles vecinos, siempre que, lógicamente, no pertenezca ya a ella.

Filtro de mayoría. El píxel central se asigna a la categoría que cuenta con la mitad más uno de los píxeles vecinos.

Otros métodos involucran el cálculo de una superficie mínima para la definición de cluster pudiendo eliminarse todos por debajo de un umbral no deseado. (CLUMP SIEVE)

Procedimientos a seguir

Clasificar una imagen es el proceso de ordenar píxeles en un número finito de clases individuales, o categorías de datos, basado en sus valores de ND.

Si un píxel satisface un cierto set de criterios, el píxel es asignado a la clase que corresponda a ese criterio.

- **Método No Supervisado**

Erdas Imagine → Main → Image Classification options → Unsupervised Classification

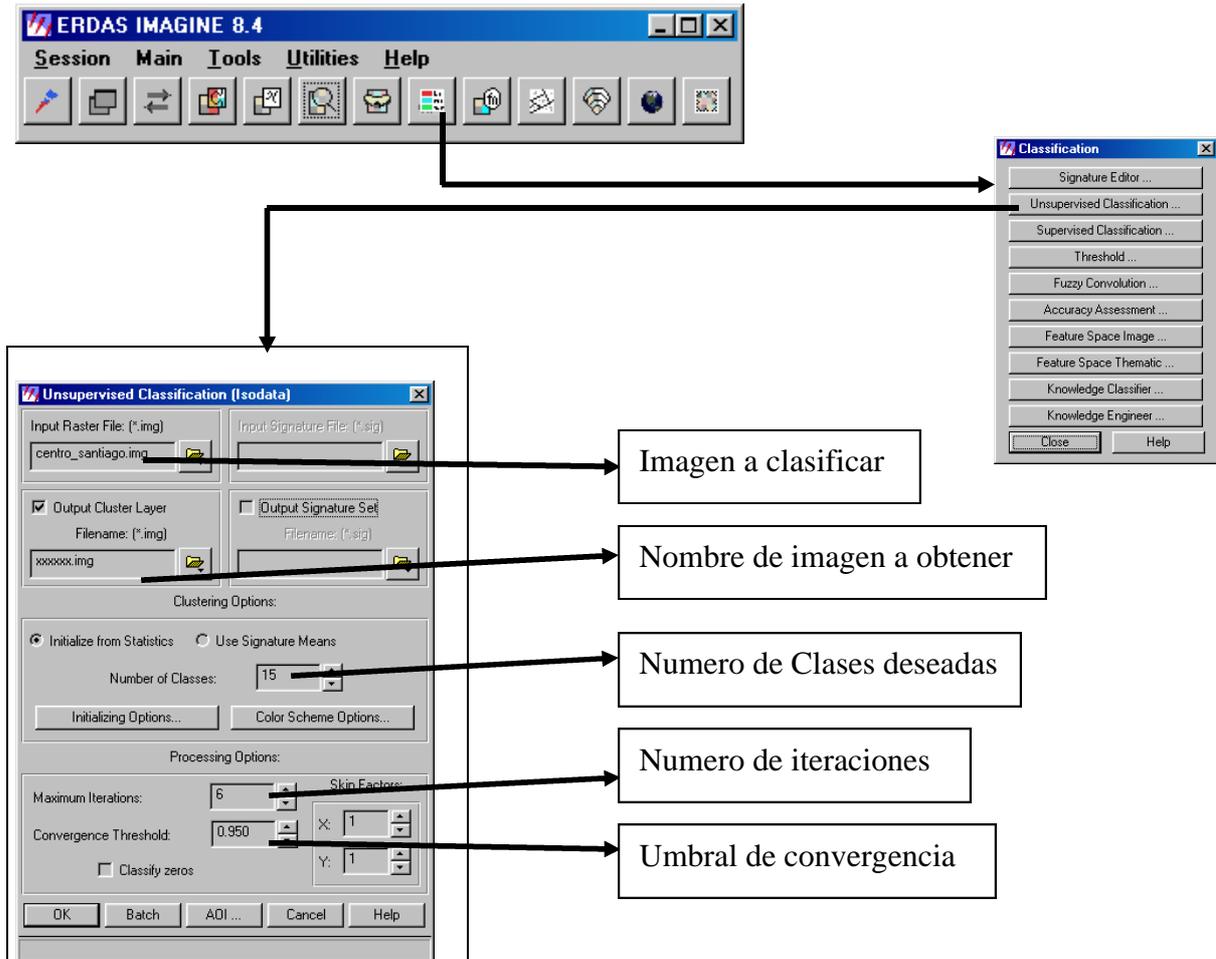


Figura 11-8: Cuadro de dialogo Clasificación no supervisada (ISODATA)

Al culminar e este proceso se genera una nueva imagen (clasificación) que al desplegarla, lo hace en tonos de grises por lo que primero realizaremos será la asignación de colores. Para ello seleccionaremos la/las clases a las que le queremos asignar un color determinado haciendo click con el botón izquierdo del ratón (mouse) y desplazándose sin soltar el botón (esto es para selecciones continuas). Para seleccionar clases no consecutivas, mantener presionada la tecla Shift mientras se realiza la selección deseada.

Posteriormente se le añadirá información a cada clase como nombres y superficie en hectáreas. Para realizar ello ir al menú Raster dentro del Viewer, elegir la opción attributes y luego Edit.

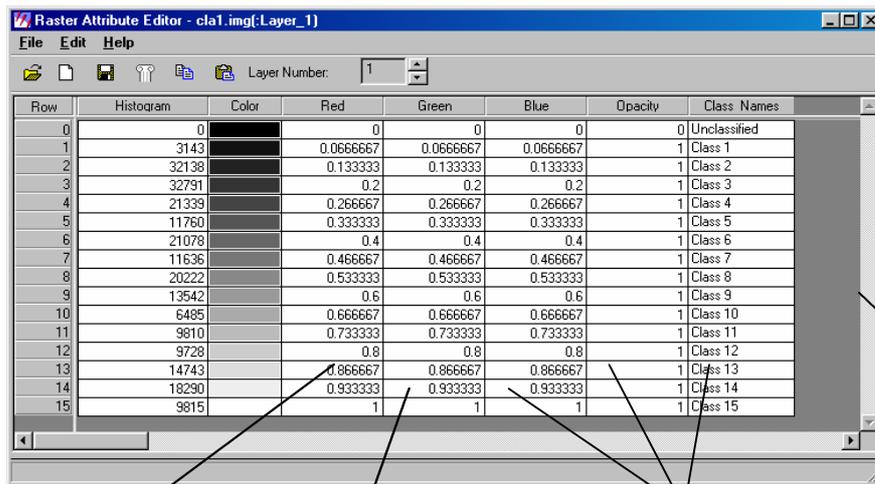


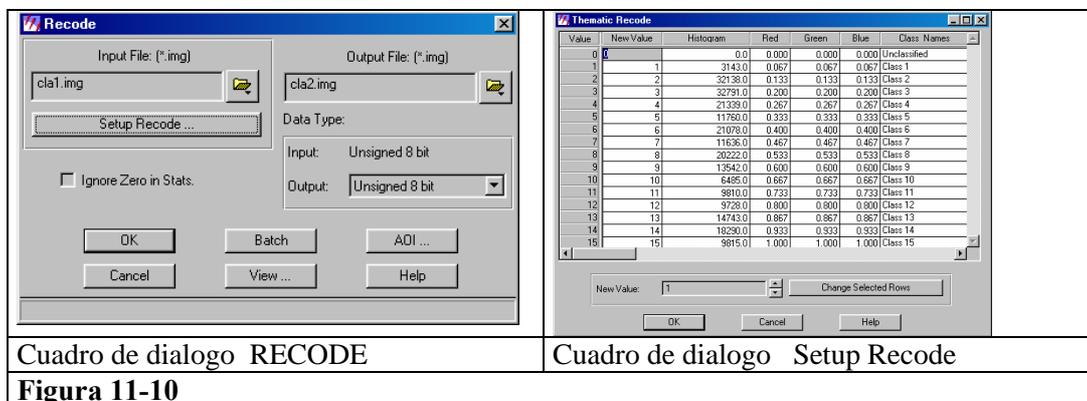
Figura 11-9



Luego de realizar este proceso debemos realizar la fase de evaluar la clasificación obtenida, para ello utilizaremos el comando RECODE, para agrupar “clases semejantes” o las que de acuerdo al operador corresponda asignar una única clase.

El comando RECODE se utiliza para asignar un numero de clase nuevo a alguna o a todas las clases, creando una nueva imagen temática. Se puede también combinar clases asignando un mismo número de clase a mas de una clase original.

Ir a Image Interpreter → GIS Analysis → RECODE → Setup Recode



Cuadro de dialogo RECODE

Cuadro de dialogo Setup Recode

Figura 11-10

Desplegar la imagen obtenida y reasignarle los colores de las clases obtenidas. Realice una impresión de la clasificación obtenida.

• **Método Supervisado**

El método supervisado es controlado mas de cerca por el operador con respecto al método no supervisado que es mas automático.

En este proceso usted selecciona píxeles que representan patrones que sean conocidos o que puedan identificarse con ayuda de otras fuentes (fotografías aéreas por ejemplo).

Se realizarán las siguientes operaciones:

- Definir las áreas de entrenamiento (firmas espectrales)
- Evaluar las firmas espectrales
- Realizar una clasificación supervisada

El modulo de ERDAS IMAGINE Signature Editor le permite crear, manejar, evaluar y editar firmas espectrales.

Se extraerá las firmas espectrales desde la imagen a ser clasificada usando area of interest (AOI)

1. Por lo tanto el primer paso es desplegar la imagen a clasificar.
2. Luego hacer click en el menú image classification



Figura 11-11

3. Use la herramienta AOI Tools para almacenar firmas espectrales

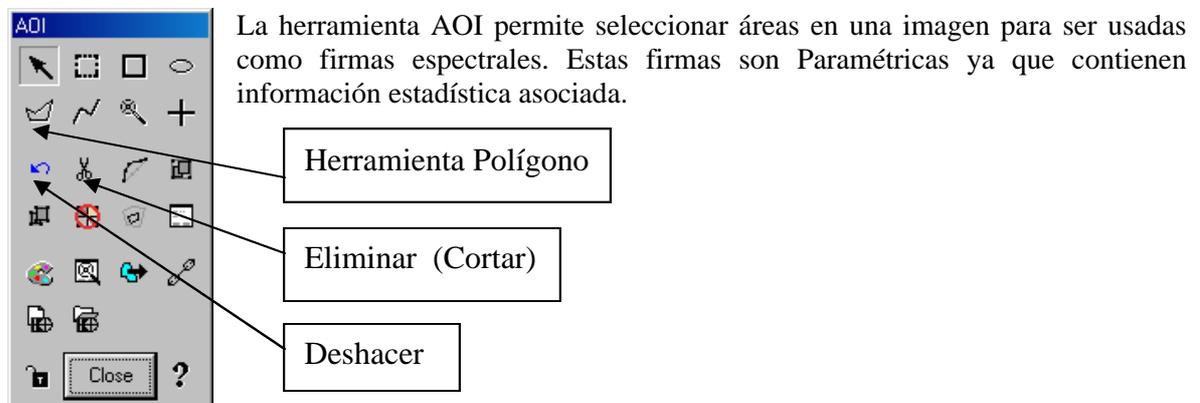
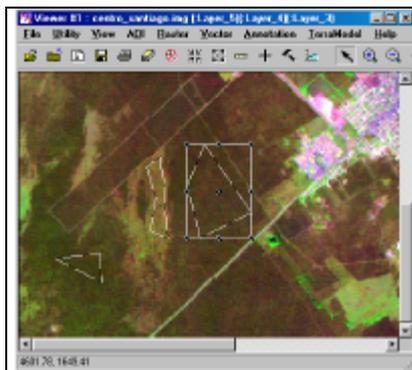


Figura 11-12



4. En la imagen desplegada dibuje un polígono que encierre un área específica. Después que el AOI es creado, un limite (borde cuadrado) engloba al AOI indicando que es el que esta seleccionado en ese momento.

Figura 11-13

5. En el editor de firmas espectrales (Signature Editor) hacer click sobre el icono Create New Signature(s) from AOI o... Seleccione Edit | Add desde la barra de menú para asignar esta AOI como firma espectral. Repetir este proceso para todas las firmas.

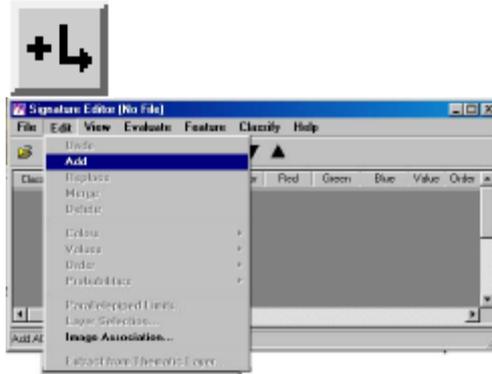


Figura 11-14

6. En el Signature Editor, haga click dentro de la columna "Signature Name" cambie el nombre a bosque1, de igual manera asigne nombres a cada firma obtenida.

7. De igual manera al paso 6 puede modificarse los colores.

Una vez que las firmas espectrales son creadas, ellas pueden ser evaluadas, borradas, y fusionadas con firmas espectrales provenientes de otros archivos.

Utilice la herramienta ALARM para evaluar las firmas espectrales.

Esta resalta los píxeles en el viewer correspondiente a la/las firmas espectrales. ALARM puede ser realizada con una o mas firmas simultáneamente.

En la barra de menú Signature Editor seleccione View | Image Alarm, un cuadro de dialogo aparece.



Figura 11-15

Los píxeles que sean clasificados por varias firmas espectrales aparecerán coloreados (en este caso de color amarillo).

Puede utilizarse una función para detectar los píxeles asignados a cada clase, mostrando alternativamente la imagen original y la imagen obtenida con ALARM. Para ello ir a UTILITY | FLICKER en el VIEWER para ver como los píxeles son clasificados.

En el caso de obtenerse regiones extensas de color amarillo, que como hemos visto estarían indicando la presencia de píxeles superpuestos, habrá que volver a obtener, fusionar o eliminar las firmas espectrales correspondientes a esa zona.

Grabe este archivo de firmas espectrales.

Aplique el proceso de clasificación Supervisada propiamente dicho, para ello ir a Image classification → Supervised Classification

Ejecute el proceso tomando las opciones de criterios de decisión por defecto.

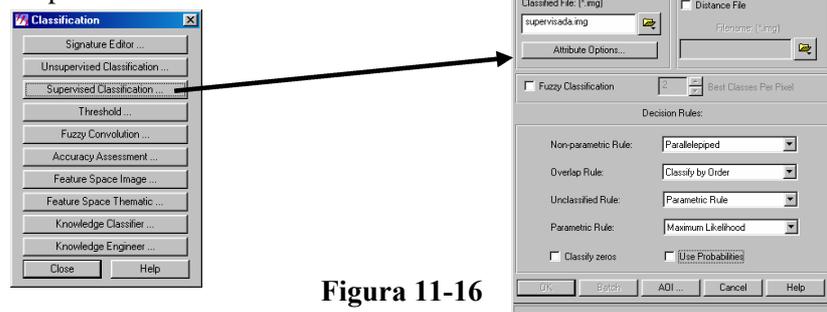


Figura 11-16

Índices de Vegetación

INDICES

Desde el menú de Erdas ejecutar image Interpreter

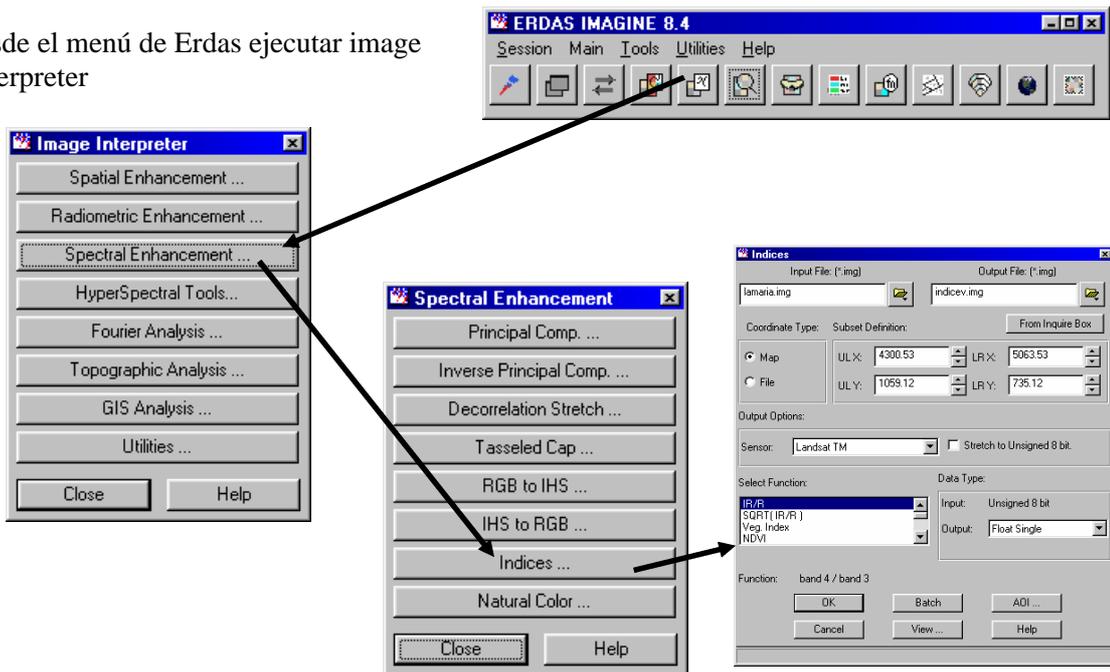
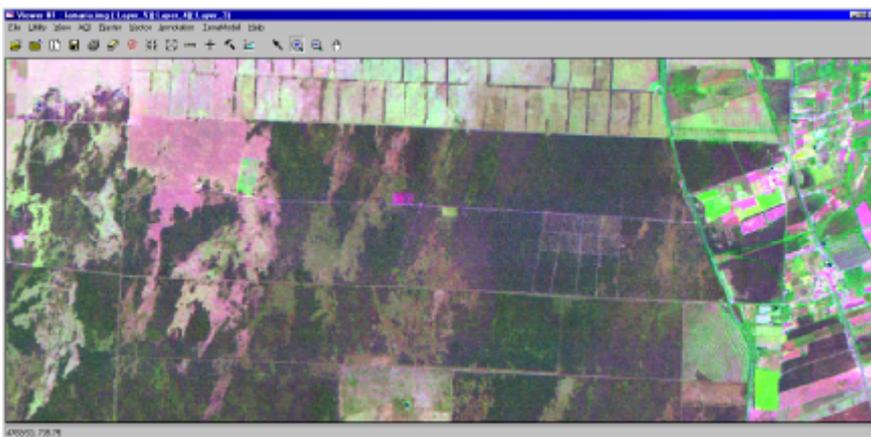
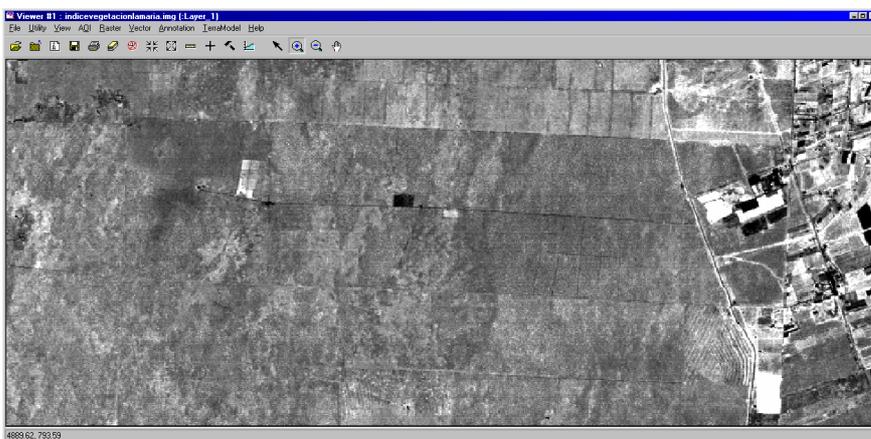


Figura 11-17



La Maria
Imagen Original
Landsat 7 TM
5,4,3 (R,G,B)



La Maria
Landsat 7 TM
Índice de
Vegetación IR / R
Banda4 / Banda 3

Figura 11-18

ANÁLISIS DE COMPONENTES PRINCIPALES

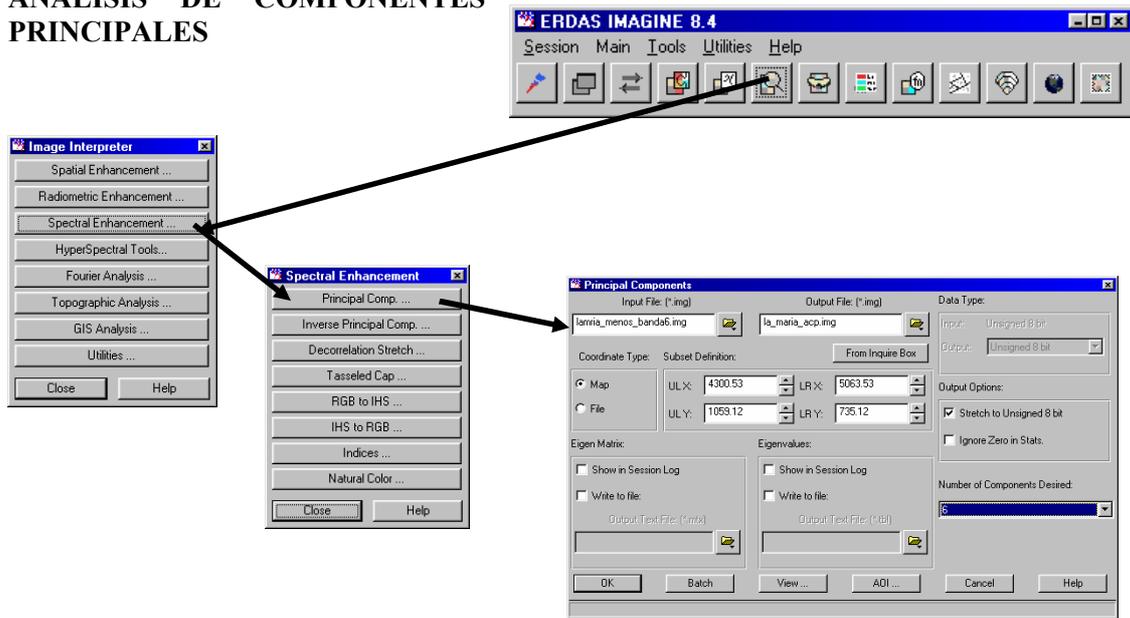


Figura 11-19

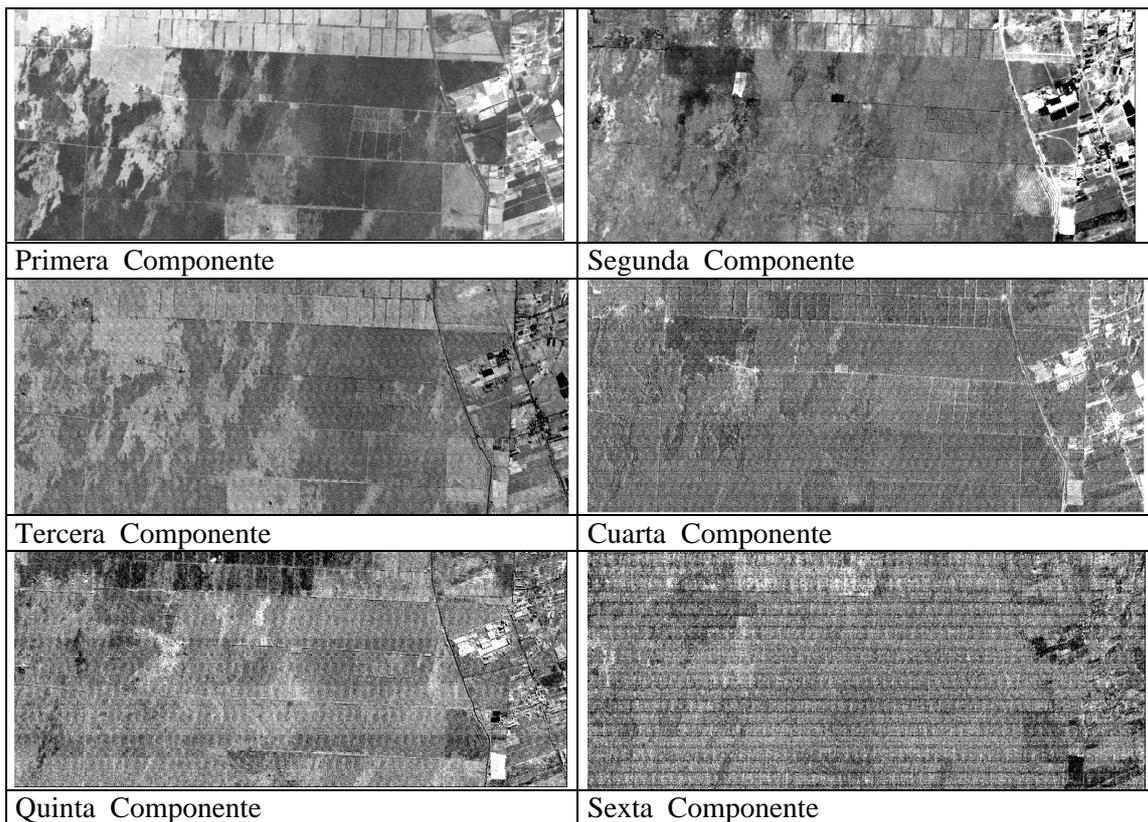


Figura 11-20

FILTRADO DE IMÁGENES

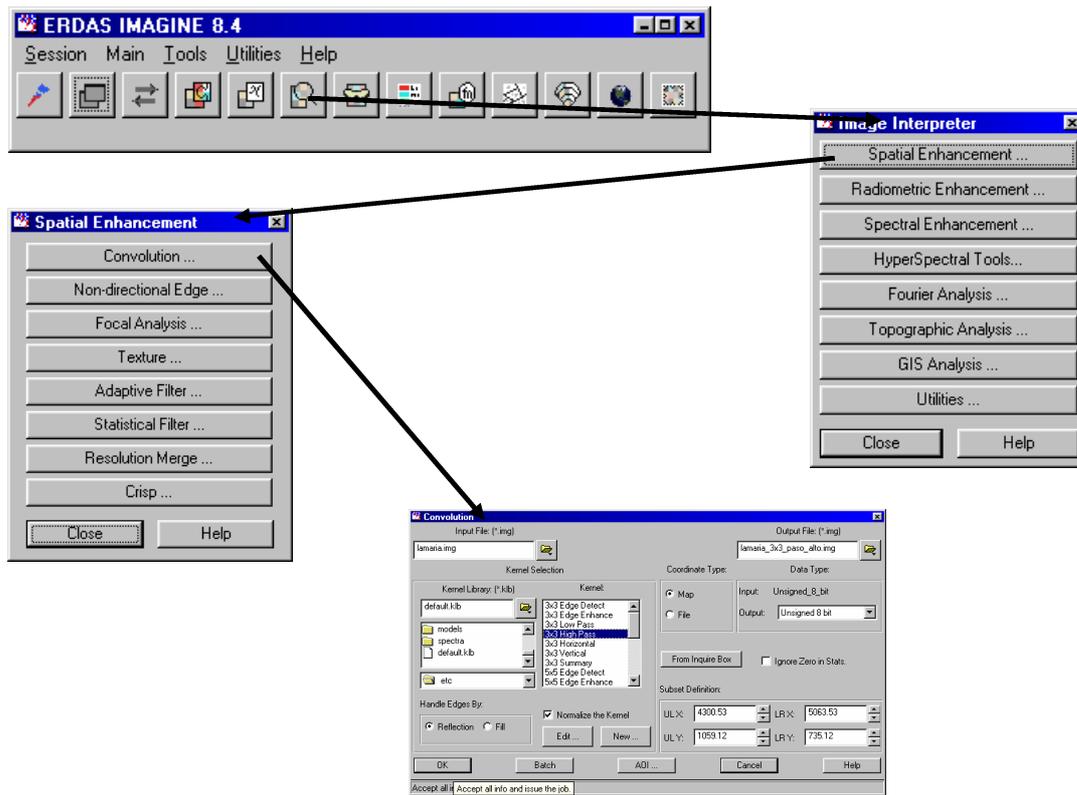


Figura 11-21

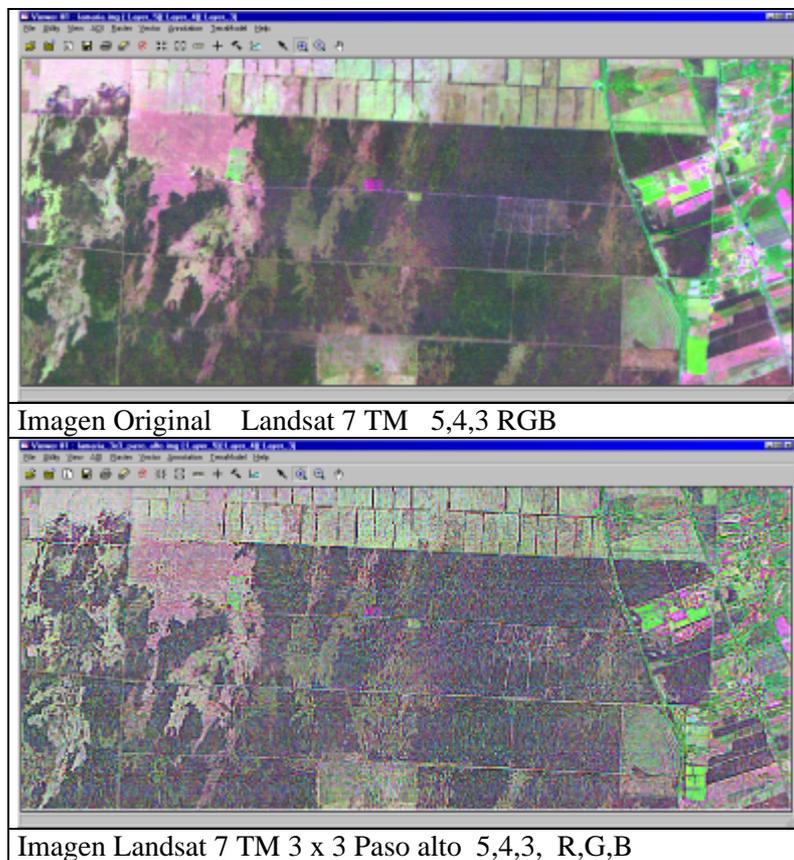


Figura 11-22

Actividades a realizar

1. Interpretación visual (IV) e Interpretación Digital (ID). Ventajas y desventajas.

De acuerdo a sus conocimientos clasifique estos principios según corresponda (IV o ID)

Inversión elevada

Inversión inicial escasa

Costes lineales

Costes se reducen con la superficie

No precisa alta especialización

Precisa alta especialización.....

Baja precisión en clases heterogéneas

Buena precisión en clases heterogéneas

Corrección geométrica sencilla y rápida.....

Restitución compleja

Inventario tedioso e inexacto

Inventario inmediato.....

Requiere conversión digital analógica.....

Permite trabajo con información original

2. del directorio de trabajo extraiga la imagen de satélite Landsat 7, correspondiente al campo La María. Realice una Clasificación No Supervisada.

3. Realice una Clasificación Supervisada del mismo Campo sobre una imagen SPOT, y compare los resultados obtenidos.

4. Obtenga un Índice de Vegetación. Explique los resultados observados.

.....

5. Realice un filtrado de paso bajo y uno de paso alto en la imagen SPOT del Campo La María. Explique con sus palabras las diferencias Observadas.

.....

6. ¿En que casos utilizaría Análisis de Componentes Principales (ACP)?

.....
