

Publicación LARS 050583

Taller Práctico en el Análisis Numérico de Datos de Imágenes Multiespectrales

**Luis A. Bartolucci
Diego Fabián Lozano G.
James C. Tilton**

Purdue University
Laboratory for Applications of Remote Sensing
West Lafayette, Indiana 47907 USA

Publicación LARS 050583

Taller Práctico en
el Análisis Numérico de
Datos de Imágenes Multiespectrales

por

Luis A. Bartolucci
Diego Fabián Lozano G.
James C. Tilton

Purdue Reaseach Foundation

Contenido

Prefacio.....	i
Capítulo I. Introducción.....	I-1
Capítulo II. Selección de los Datos del Barredor, Correlación con los Datos de Referencia y Selección de las Muestras de Entrenamiento.....	II-1
Selección del conjunto de datos.....	II-2
Localización del área de estudio y correlación con los datos de referencia.....	II-5
Selección de las muestras de entrenamiento.....	II-7
Capítulo III. Definición Estadística de las Clases Espectrales de Entrenamiento.....	III-1
Agrupación de las Muestras de Entrenamiento.....	III-2
Asociación de las Clases Candidatas de Entrenamiento con las Clases Informacionales.....	III-7
Aumento de las Clases Candidatas de Entrenamiento.....	III-10
Representación Visual de las Clases Candidatas de Entrenamiento.....	III-11
Cálculo de la Distancia Estadística entre las Clases Candidatas de Entrenamiento.....	III-12
Refinamiento de las Clases Espectrales de Entrenamiento....	III-18
Capítulo IV. Clasificación del Area de Estudio.....	IV-1
Capítulo V. Reapresentación Pictorica o Tabular de los Resultados de la Clasificación.....	V-1
Capitulo VI. Evaluación de los Resultados de la Clasificación.....	VI-1
Capitulo VII. Consideraciones Finales.....	VII-1

PREFACIO

Durante muchas décadas, el hombre ha recolectado y analizado datos de percepción remota con el objeto de conocer mas acerca de la superficie terrestre. A partir del desarrollo de los barredores multiespectrales en la década del 60, los datos de percepción remota son obtenidos y almacenados en forma digital. Este formato permite utilizar la computadora como una ayuda para el análisis. De hecho, a partir de 1972 con el gran volumen de datos producidos por el satélite Landsat y otros barredores multiespectrales instalados en satélites, la computadora se ha convertido en una parte necesaria del proceso de análisis, debido al hecho de la gran cantidad de datos involucrados. La computadora puede ser utilizada incluso si el volumen de datos no fuera de consideración. La computadora puede ayudar al analista en utilizar mas efectivamente el contenido de información de los datos.

Existen numerosas técnicas de análisis por computadora, basadas en el concepto de reconocimiento de patrones. Este taller presenta una introducción a estas técnicas de reconocimiento de patrones a través de una serie de ejercicios que simulan el analisis de datos de un barredor multiespectral. El propósito de este taller no es el de entrenarlo como analista, pero sí ofrecerle un panorama general y la comprensión de la forma en que los datos de los barredores multiespectrales son analizados. Usted obtendrá este aprendizaje por medio del entendimiento de las características de los datos de los barredores multiespectrales y las técnicas de reconocimiento de patrones así como realizando las decisiones que el analista debe hacer.

Cada capítulo de este manual consiste de una discusión general de cada fase en el análisis, seguido por un caso de estudio especializado que ilustra el proceso descrito en la discusión general. El problema en el caso de estudio es un análisis por computadora de datos de un barredor multiespectral seleccionado a partir de varios disponibles. Este caso de estudio es presentado como un ejemplo de como un análisis numérico debe ser ejecutado en un particular conjunto de datos. No debe ser visto como la unica forma de análisis.

Si bien los datos del satélite Landsat son mencionados frecuentemente en este manual, la discusión general esta desarrollada de tal manera que puede ser aplicada a datos de barredores multiespectrales de cualquier origen, no obstante observará una inclinación hacia los datos basados en satélites. El caso de estudio que usted analizará puede estar basado en datos Landsat o de otro origen. Cuando se presenten consideraciones especiales asociadas a datos diferentes de Landsat, se realizará la anotación apropiada.

El caso de estudio presentado en este manual fué realizado utilizando el sistema de análisis numérico LARSYS. Igualmente, varios procesadores de LARSYS son descritos en la discusión general

como una ilustración de los procedimientos de análisis. Usamos LARSYS solo como un ejemplo de los sistemas de análisis numérico. Resultados semejantes pueden ser obtenidos utilizando otros paquetes de programas de análisis de imágenes de percepción remota.

Usted no utilizará la computadora en el transcurso de este taller. El instructor ha ejecutado los programas para analizar los datos. Sin embargo, usted observara los datos de entrada y los listados de los resultados de cada secuencia de análisis y aprenderá la forma de realizar las decisiones necesarias. Su instructor le proporcionará los listados de computadora para este caso de estudio.

Este taller esta diseñado para personas que poseen una formación basica en percepción remota. Esta formación puede ser enriquecida con el siguiente material educativo o equivalente:

"An Introduction to Quantitative Remote Sensing"
by J. C. Lindenlaub and James D. Russell,
LARS Information Note 110474, Laboratory for Applications of
Remote Sensing, Purdue University, West Lafayette, Indiana
47907.

Fundamentos de la Percepción Remota. Series de Minicursos. En particular, las siguientes unidades:

- Percepción remota: Que es?
- La Base Física de la Percepción Remota.
- Características de la Reflectancia Espectral de la Vegetación.
- Características de la Reflectancia Espectral de los Detalles de la Superficie Terrestre.
- Barredores Multiespectrales.
- Interpretación de Imágenes de Barredores Multiespectrales.
- Reconocimiento de Patrones en Percepción Remota.
- Pasos Tipicos en el Análisis Numérico.

Introducción al Análisis Cuantitativo de los Datos de Percepción Remota. Series de Videotapes. En particular, las siguientes unidades:

- The Remote Sensing Information System.
- El Papel del Reconocimiento de Patrones en la Percepción Remota.

La información basica puede ser obtenida, estudiando los capítulos introductorios de los siguientes textos:

Remote Sensing of Environment
J. Lintz, Jr and D.S. Simonett, eds.
Addison and Wesley Publishing Company, Reading, MA, 1976.

Remote Sensing: The Quantitative Approach.
P. H. Swain and S. M. Davis, eds.,
McGraw-Hill Book Company, New York, NY, 1978.

Remote Sensing and Image Interpretation.
T. M. Lillesand and R. W. Kiefer,
John Wiley and Sons, New York, NY, 1979.

Estos textos son también referencias útiles para este taller.

El manual de este taller está basado en los materiales presentados en el trabajo: Series de Talleres en Análisis Numérico de Datos de Percepción Remota por Ronald K. Boyd y John C. Lindenlaub. Los autores desean agradecer a Shirley M. Davis, Joan S. Buis, Roger M. Hoffer y Carlos Valenzuela por sus comentarios y sugerencias para la edición de este manual.

CAPITULO I. INTRODUCCION

El análisis numérico de datos de barredores multiespectrales es un proceso dinámico que requiere la interacción entre el hombre (analista) y la máquina (computadora). Este proceso involucra la mezcla de la experiencia y el conocimiento profundo del analista con los adecuados programas de computadora, para extraer la máxima cantidad de información de los datos. Las técnicas de análisis numérico permiten el estudio detallado de datos digitales y se ha demostrado que en muchos casos son eficientes en costos. La secuencia típica de análisis se muestra en la figura I-1. A pesar de que se muestra como un proceso lineal, todos los pasos están interrelacionados. En cada paso del análisis, la interpretación de los resultados de dicha fase puede resultar en el regreso a pasos previos para realizar una revisión de los resultados de dicho proceso.

El análisis numérico de datos multiespectrales es en cierto sentido un arte, ya que a pesar de que existen guías generales para el análisis, no hay un método definitivo y único que pueda ser aplicado a todos los distintos tipos de datos. Cada analista estudiará un particular conjunto de datos de diferente manera. Además, distintos conjuntos de datos podrán ser analizados de diferente manera por un mismo analista, dependiendo de las características de los datos y la información que se desea obtener como resultado del análisis.

Los capítulos II al VI discuten cada paso en el análisis, pero antes de revisar cada fase en particular, debemos estudiar ciertas características generales de los datos de barredores multiespectrales.

Un barredor multiespectral recolecta datos de reflectancia en varias porciones del espectro electromagnético (bandas de longitud de onda). El número de estas bandas y el intervalo del espectro electromagnético que cubren, depende de cada barredor en particular. Por ejemplo, el barredor del satélite Landsat posee cuatro bandas que cubren la mayor parte de visible y el infrarrojo cercano. El barredor a bordo del Laboratorio Espacial (Skylab) poseía trece bandas que cubrían el visible, infrarrojo cercano y medio, así como parte del lejano (térmico) infrarrojo.

Cada barredor multiespectral posee una resolución espacial particular, esto significa que existe un límite con respecto al tamaño mínimo de un objeto que puede ser detectado. La resolución espacial, la cual está determinada por la óptica del barredor y su altitud, controla el tamaño del elemento de resolución o el área del terreno cubierta por cada elemento de resolución (pixel, del inglés picture element) en los datos. La resolución del barredor del satélite Landsat es aproximadamente de 56m. por 79m. El barredor del Skylab poseía una resolución espacial parecida a la de Landsat. El Mapeador Temático a bordo del satélite Landsat-4 posee una resolución de 30m. por 30m.

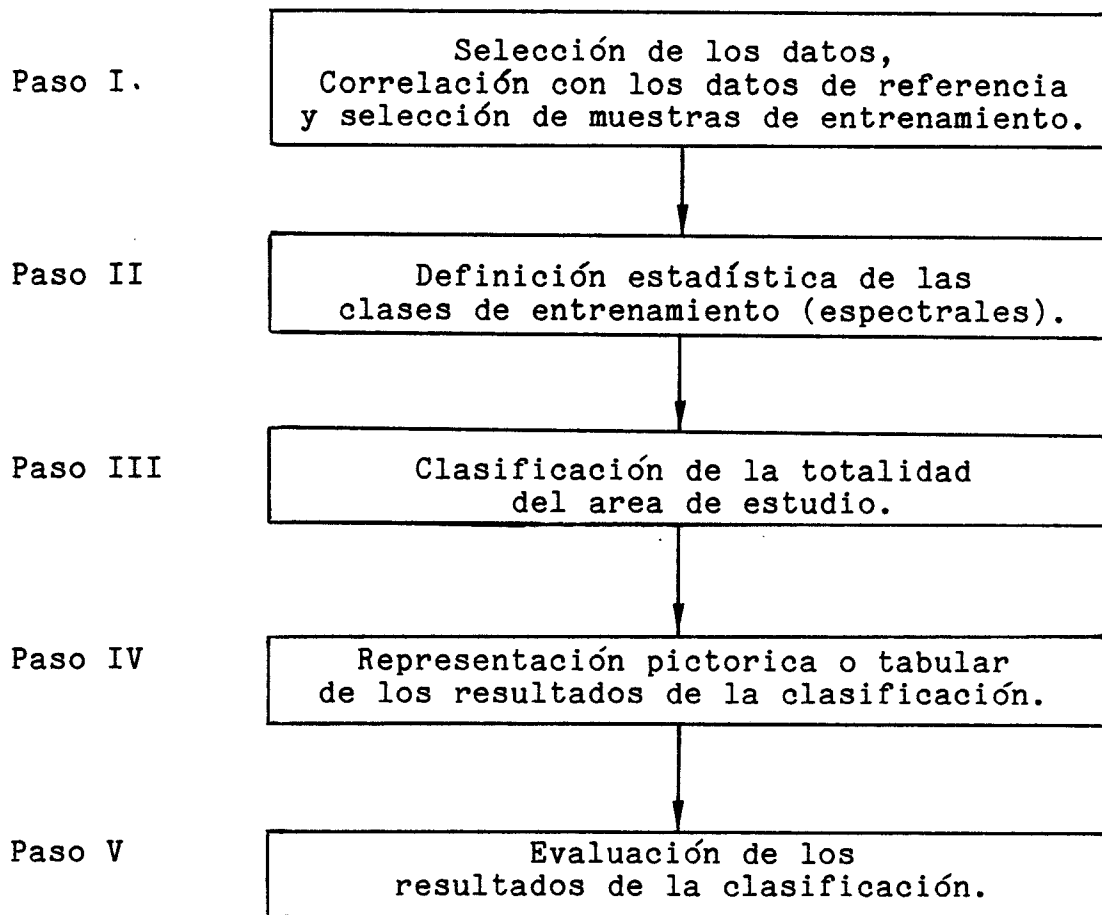


Figura I-1. Diagrama de flujo de los pasos en el análisis para la clasificación de datos de barredores multiespectrales.

Para cada línea de datos obtenida por el barredor se registran señales de calibración. Un conjunto diferente de señales de calibración son grabadas para cada detector del barredor. Estas señales de calibración son usadas para corregir inconsistencias en la electrónica del barredor, durante la recolección de los datos, así como para la conversión de los datos a unidades radiométricas. Los valores convertidos a unidades radiométricas pueden ser comparados en cualquier banda de longitud de onda y pueden ser también comparados con datos a diferente tiempo, no importando el hecho de que hayan sido recolectados por distintos sensores. En la región del visible y el infrarrojo cercano, la calibración se realiza por medio de una superficie negra en el interior del barredor y utilizando como referencia una lámpara o la luz del sol. Para la porción del infrarrojo térmico la calibración se realiza por medio de placas frías y calientes de temperatura conocida. El barredor del satélite Landsat utiliza solamente placas negras y lámparas incandescentes como referencias para la calibración. La

calibración del Mapeador Temático se realiza por medio de tres lámparas de tungsteno que son encendidas y apagadas para proveer 8 niveles de calibración desde, obscuridad total hasta iluminación completa.

La descripción de las características espectrales, espaciales y radiométricas de los datos de barredores multiespectrales, se presenta aquí como una revisión breve de los barredores, pero que por ningún motivo se puede considerar exhaustiva. Para una descripción mas completa de los datos y sistemas de los barredores multiespectrales se recomienda las secciones 2.6, 2.7 y 2.8 del libro de Swain y Davis, Remote Sensing: The Quantitative Approach.

CAPITULO II. SELECCION DE LOS DATOS DEL BARREDOR, CORRELACION CON
LOS DATOS DE REFERENCIA Y SELECCION DE LAS MUESTRAS DE
ENTRENAMIENTO.

Despues de la lectura de este capítulo, Usted sera capaz de:

1. Presentar, por lo menos una razón del por que la calidad de los datos que se desea utilizar, debe ser evaluada.
2. Mencionar dos formas para evaluar la calidad de los datos.
3. Conocer al menos tres problemas relacionados con la calidad de los datos, que pueden obstaculizar el análisis.
4. Describir dos tipos de correcciones geométricas que pueden auxiliar en el análisis de imagenes del satelite Landsat.
5. Presentar alguna razón del por que es necesario correlacionar los datos de los barredores multiespectrales con los datos de referencia.
6. Detallar, por lo menos cuatro tipos de datos de referencia.
7. Describir la correlación que existe entre los rasgos del terreno que aparecen en la imagen del barredor con los mismos rasgos presentes en los datos de referencia.
8. Explicar por que se requieren muestras de entrenamiento.
9. Presentar las diferencias que existen entre el método supervisado y el no-supervisado para obtener las muestras de entrenamiento.
10. Nombrar al menos dos consideraciones que afectan la selección de muestras de entrenamiento en el metodo hibrido de selección de estadísticas de entrenamiento.

El primer paso en la clasificación de datos multiespectrales, comienza con la selección del conjunto de datos. Este conjunto de datos debe poseer una calidad adecuada y ser de la época del año apropiada con el objeto de que las clases de cobertura del suelo de interés puedan ser identificadas con la precisión requerida. De otra manera, por mas cuidadosamente que se realice el análisis, no sera posible obtener los resultados deseados. A continuación debemos localizar el área de estudio en los datos del barredor y correlacionar dichos datos con la información de referencia. Una vez hecho esto, los datos de referencia pueden ayudarnos a seleccionar las muestras de entrenamiento de los datos multiespectrales. Estas muestras de entrenamiento serán utilizadas posteriormente para definir estadísticamente las clases de entrenamiento (clases espectrales), las cuales serán usadas para entrenar al clasificador.

SELECCION DEL CONJUNTO DE DATOS.

Antes de seleccionar nuestro conjunto de datos multiespectrales, debemos considerar las características de los tipos de cobertura del terreno que nos interesan ya que estas pueden limitar la selección de los datos. Algunas clases de cobertura pueden aparecer solo en alguna época del año, otras clases pueden ser fácilmente distinguibles espectralmente de otras clases en determinadas estaciones del año. Por ejemplo, los cultivos agrícolas solo pueden ser detectados durante el periodo de germinación a cosecha, las coníferas son más fácilmente identificadas en el invierno (cuando las especies caducifolias carecen de hojas) y los suelos son estudiados más fácilmente durante el otoño (después de la cosecha y antes de las primeras nevadas) o durante la primavera (después de las nieves y antes de la aparición de las primeras plantas).

Después de haber seleccionado la fecha o fechas del año de nuestros datos, lo siguiente a considerar es la calidad general de los conjunto de datos escogidos. Esto incluye la calidad radiométrica así como la posible presencia de nieve y nubes en las imágenes.

Una idea general de la calidad de los datos y cobertura de nubes en las imágenes Landsat para un área geográfica determinada, puede ser obtenida en los listados que provee el centro de datos EROS (en Sioux Falls, Dakota del Sur). EROS examina todas las imágenes que recibe en sus instalaciones y califica su calidad, canal por canal en una escala de 0 a 9, con 9 indicando la más alta calidad. También se incluye una estimación a groso modo de la cobertura de nubes. Si Usted está utilizando imágenes diferentes a Landsat, puede solicitar información similar. Con este tipo de información nosotros podemos seleccionar para una inspección más detallada, imágenes de calidad y cobertura de nubes aceptables, para la época del año más adecuada para discriminar entre los tipos de cobertura de interés en el área de estudio.

Una vez que se han eliminado los conjuntos de datos de menor calidad a través del proceso anteriormente mencionado, podemos realizar una evaluación más refinada de los datos restantes, examinando directamente los datos en forma pictórica. Para los datos Landsat, podemos obtener del Centro EROS, fotografías de cada una de las bandas de las imágenes de interés. Si Usted está utilizando datos diferentes a Landsat, puede solicitar información acerca de la disponibilidad de este tipo de imágenes para la zona de interés.

Las características más obvias, incluyendo la cobertura de nubes, son obvias en la representación pictórica de los datos. La figura II-1 muestra un ejemplo fotográfico de una imagen Landsat del área de Chicago, Illinois. Las nubes se observan claramente sobre la porción Este de la imagen; esta muestra muy claramente el problema que existe en la forma de estimación de la cobertura de nubes, utilizada en EROS. Si nosotros deseáramos realizar un estudio

en la región de Chicago, esta imagen poseería una cobertura de nubes del 0 %. Mientras que la cobertura de nubes que EROS presenta es del 20 %.




Figura II-1. Imagen Landsat del area de Chicago, Illinois mostrando la cobertura de nubes en la porcion Este de la escena.

Un ejemplo dramático del problema de calidad de los datos se muestra en la figura II-2. En el barredor del satélite Landsat, se obtienen seis líneas de datos por cada banda de longitud de onda cada vez que el espejo del barredor oscila. Un conjunto diferente de detectores es usado para cada una de estas líneas. Si estos detectores y sus componentes electrónicos asociados no se encuentran adecuadamente calibrados, se observará en las imágenes de una o más de las bandas espectrales, líneas paralelas tal y como se muestra en la figura II-2. La tabla en la figura muestra los valores de media y desviación estandar de los datos de cada uno de los seis detectores en la banda 4 de la imagen que se muestra en la figura II-2. Observe

que la media del detector 3 es menor comparada con los valores de los otros detectores. Aparentemente, ocurrió una falla en los componentes electrónicos del detector, resultando en la presencia de líneas en la imagen en la figura II-2. Otro tipo de problemas en la calidad de las imágenes es la pérdida de líneas de barrido o líneas de datos con ruido, normalmente producidas por defectos de funcionamiento en los detectores o sus componentes electrónicos. Estos problemas en la calidad de los datos pueden ser compensados utilizando técnicas de restauración de imágenes. Actualmente, el centro de datos EROS procesa la mayoría de los datos Landsat para compensar este tipo de problemas radiométricos y geométricos.



Figura II-2. Efecto de líneas defectuosas en la imagen.

Detector	Media	Desviación Estandar
1	21.9	3.21
2	21.8	3.07
3	7.0	3.13
4	21.5	3.13
5	20.9	3.11
6	21.9	3.03

Después de que hemos examinado la calidad de las imágenes y la cobertura de nubes para cada uno de los posibles conjuntos de datos, podemos ordenar cintas compatibles con computadora de uno o más de los conjuntos de datos para realizar análisis por computadora. Es importante señalar que no es necesario adquirir las cintas de computadora relativamente caras, solo hasta que se haya seleccionado el conjunto de datos que utilizaremos para el análisis.

Una vez que contamos con las cintas de computadora del juego de datos de interés, podemos desplegar toda la imagen o porciones de esta. Realizamos esto para verificar nuevamente la calidad de la imagen y como un elemento auxiliar en los siguientes pasos del análisis. Nosotros podemos desplegar los datos utilizando un monitor de televisor, una impresora o un impresor de rayos laser.

LOCALIZACION DEL AREA DE ESTUDIO Y CORRELACION CON LOS DATOS DE REFERENCIA

Después de haber escogido el mejor conjunto de datos disponible para el análisis, debemos localizar el área de estudio y correlacionar los datos de referencia de que dispongamos (fotografías aéreas, mapas etc.) con los datos del barredor multiespectral. Este proceso se simplifica si utilizamos datos que hayan sido corregidos geoméricamente y reescalados para permitir una superposición directa con los datos de referencia en forma de imagen.

Las imágenes generadas por los datos Landsat no corregidos presentan un fenómeno en el que los objetos rectangulares en el terreno, aparecen como paralelogramas sesgados. Este fenómeno es causado por la rotación de la tierra. Puesto que la órbita de Landsat no está orientada exactamente sobre los polos, una imagen Landsat no corregida se encuentra desalineada de la línea de los polos (alrededor de 12 a 40 grados de latitud norte). Esta deformación y rotación pueden ser corregidas por una transformación geométrica de los datos por computadora. Un ejemplo de esto se muestra en la figura II-3 en la que se despliega una imagen antes y después de la corrección geométrica.

Durante la corrección geométrica, los datos pueden ser reescalados. Los datos del barredor pueden ser modificados para que correspondan con mapas topográficos del Servicio Geológico (escala 1:24,000) o cualquier otra escala deseada que permita a los datos del barredor ser superpuestos sobre los mapas de referencia. Dado que los datos no corregidos son solo útiles para algunos pasos en el análisis, el utilizar datos corregidos geoméricamente, simplifica el trabajo del analista al localizar rasgos en el terreno puesto que los datos se pueden superponer con los mapas y comparar fácilmente con otros datos de referencia. La comparación de mapas u otros datos de referencia en forma de imagen con los datos del barredor corregidos geoméricamente en una forma conveniente y efectiva de localizar el área de estudio en el conjunto de datos.

Los datos de referencia en forma de mapas pueden encontrarse en diversas presentaciones. Una de estas son las fotografías aéreas. Estas pueden ser obtenidas a varias altitudes, resultando en datos de referencia de escala variable. En general, si el avión vuela mas alto (o la distancia focal del objetivo de la cámara se reduce), cada fotografía cubrira un área mayor del terreno, pero los detalles reproducidos disminuyen. Otra variable en las fotografías aéreas es el tipo de película. Blanco y negro pancromática, blanco y negro infrarroja, color y color infrarroja; cada una provee diferentes tipos de informacion sobre el terreno y pueden ser utilizados como datos de referencia por un analista capacitado en la interpretación de fotografías.




Figura II-3. Imagen Landsat antes y después del procesamiento para corregir el efecto de la rotación de la tierra.

Los datos de barredor multiespectral instalado en avión pueden ser utilizados como referencia por un analista que trabaje con datos de satélite. Los datos obtenidos en avión ofrecen generalmente información mas detallada sobre las características espectrales de partes de la escena, en comparación con las imagenes de satélite. Por ejemplo, en barredores montados en avión, los sensores poseeran mas bandas espectrales y los datos disponibles tendrán una mayor resolución espacial y espectral.

Es importante hacer notar que las fotografías aéreas, así como los datos de barredores multiespectrales montados en avión pueden presentar distorsiones importantes en comparación con un mapa. A las alturas que estos datos son obtenidos algunos rasgos tales como edificios o montañas, distorsionan la imagen desviándola de la calidad cartográfica. Además, encontraremos otro tipo de distorsiones causadas por movimientos indeseados del aeroplano, tales como cabeceo, ladeo y giro, desplazamiento de la línea de vuelo y variaciones en la velocidad y altura de vuelo. Nosotros.

debemos ser cuidadosos para evitar este tipo de problemas al utilizar esta clase de datos de referencia.

Los mapas (por ejemplo mapas de carreteras o del Servicio Geológico) así como registros históricos (como registros de cultivos o datos climáticos) pueden ser de utilidad para el analista al brindarle información sobre las características del área de estudio.

Otra fuente de información es la observación directa por el analista u otra persona. Esto se denomina comunmente "verificación de campo" o "verdad de tierra". Esta información puede incluir la obtención de muestras de suelo, identificación de variedades de cultivos, determinación de biomasa y otras observaciones. Estas pueden ofrecer la clave para la correlación adecuada de la respuesta espectral de los datos con los tipos de cobertura.

SELECCION DE LA MUESTRAS DE ENTRENAMIENTO

El siguiente paso en el análisis de datos de barredores multiespectrales es la selección de las muestras de entrenamiento. Con el objeto de entender que son y el por que son necesarias estas muestras, es necesario revisar algunos conceptos sobre reconocimiento de patrones. Los algoritmos de reconocimiento de patrones con los que nosotros trabajaremos requieren que se le proporcione al computador, ejemplos de datos típicos de cada clase de interés. Estos datos, llamados muestras de entrenamiento, son utilizados para estimar ciertos parámetros de los algoritmos de reconocimiento de patrones, y de esta manera "entrenar" al computador a reconocer las clases de interés. Cuando la clasificación es realizada por los algoritmos de reconocimiento de patrones, cada punto a clasificar es "comparado" con las muestras de entrenamiento de cada clase, y el elemento es asignado a la clase a la que mas se asemeja.

Existen dos métodos básicos para obtener las muestras de entrenamiento. El primero, conocido como el método supervisado, involucra la localización de regiones de elementos puros, cada región representando a un solo tipo de cobertura. Nosotros localizamos en los datos de referencia varias de estas regiones para cada clase de cobertura, y encontramos las regiones respectivas en los datos del barredor. Las muestras de entrenamiento para cada clase se forman agrupando los datos de todas las regiones identificadas en los datos del barredor como pertenecientes a una clase de cobertura. El segundo método, conocido como no supervisado, no utiliza datos de referencia para seleccionar los elementos de la muestra de entrenamiento. En este caso, un conjunto sistemático o aleatorio de elementos es seleccionado del area de estudio. Esta muestra es analizada para encontrar grupos de elementos que sean similares espectralmente. La identidad del tipo de cobertura de cada grupo de elementos es establecida comparando los elementos de cada grupo con los datos de referencia.

En resumen, en el método supervisado nosotros especificamos las

clases de cobertura del terreno de interés y localizamos muestras para cada una de estas clases en los datos multiespectrales. En el método no-supervisado nosotros analizamos una muestra sistemática o al azar de los datos multiespectrales para identificar clases espectrales similares. Posteriormente asignamos estas clases espectrales a alguna clase de cobertura.

El método supervisado posee en su favor el hecho de que garantiza el que los tipos de cobertura y regiones de mayor interés se encuentren representados en las muestras de entrenamiento. Nosotros podemos asegurar esta representación a través de una cuidadosa selección de los campos de elementos puros. Un problema con este método es el que a pesar de que seleccionemos las muestras de entrenamiento muy cuidadosamente, estas pueden no reflejar la variabilidad espectral de cada una de las clases de cobertura. La precisión de la clasificación puede reducirse si nuestras muestras de entrenamiento no son espectralmente representativas de cada una de las clases de cobertura del terreno. Otro problema es que, para la mayoría de los conjuntos de datos, muchos de los elementos no están compuestos de una sola clase de cobertura. Al utilizar el método supervisado, nosotros no seremos capaces de producir una clasificación precisa cuando se presenten en el conjunto de datos, un número importante de elementos mixtos, ya que con este método el computador no está entrenado para reconocer elementos mixtos.

El método no-supervisado posee en su favor, la habilidad de agrupar elementos espectralmente similares, sin importar su posición espacial. Esto puede ser una ventaja si trabajamos en una zona heterogénea, donde la posibilidad de observar elementos espectralmente similares adyacentes es baja. Un ejemplo de esta condición puede ser un área de terreno montañoso con muchas combinaciones de pendiente, orientación, elevación y vegetación. Un problema con el método no-supervisado es que clases de cobertura importantes pero poco frecuentes, pueden ser pasadas por alto en el muestreo sistemático o al azar de este método.

Un error común es el asumir que puntos adyacentes y pertenecientes a la misma clase de cobertura, presentarán la misma respuesta espectral. Esto no es estrictamente cierto. Si nosotros imaginamos un campo de maíz, la experiencia nos dice que dentro de este campo, encontraremos áreas donde el maíz es más verde y con mayor crecimiento y cobertura; así como áreas con deficiencias de agua y por tanto con las plantas más pequeñas y el suelo es "visto" por el sistema sensor (en años de lluvias excesivas, se observaría el efecto contrario). Existen muchas otras razones para explicar la variabilidad espectral de un tipo de cobertura del terreno, y muchos de estos son representados por dos o más grupos de elementos espectralmente diferentes. Nosotros podemos utilizar el método no supervisado para identificar la variabilidad espectral de cada uno de los tipos de cobertura del terreno.

Existe otro método para obtener las muestras de entrenamiento, que combina aspectos de los dos métodos anteriores. Tal y como se

realiza en el método supervisado, las muestras de entrenamiento son definidas seleccionando regiones de elementos con base en los datos de referencia. Sin embargo, en el método híbrido estas regiones, llamadas áreas o campos de entrenamiento, son seleccionadas conteniendo varios tipos de cobertura del terreno. Una vez que las muestras de entrenamiento son definidas de esta manera, el área es analizada, de la misma forma que en el método no supervisado, para identificar los grupos de elementos similares espectralmente. La identidad del tipo de cobertura de cada grupo de elementos es establecida comparando los elementos de cada grupo con los datos de referencia.

Este método híbrido nos permite utilizar las ventajas de ambos métodos, supervisado y no-supervisado y al mismo tiempo, evitar los problemas inherentes a cada uno. Nosotros podemos seleccionar las áreas de entrenamiento de tal manera que los tipos de cobertura y regiones de interés queden incluidas en las muestras de entrenamiento, tal y como lo hacemos en el método supervisado. Pero como estas son procesadas para identificar elementos similares espectralmente dentro del área de estudio, como en el método no-supervisado, la variabilidad espectral de los tipos de cobertura es identificable.

El primer paso para obtener las muestras de entrenamiento en el método híbrido es la selección de las áreas de entrenamiento. La experiencia indica que el paso de identificar grupos de elementos similares espectralmente es facilitado si escogemos áreas de entrenamiento grandes ya que esto hace más sencillo correlacionar estos con los datos de referencia. El sistema de cómputo utilizado impone un límite al tamaño máximo de las áreas de entrenamiento. Para LARSYS existe un límite de 25,000 elementos para datos en un solo canal o 40,000 elementos divididos por el número de canales en un conjunto de datos multiespectrales. Por ejemplo, un conjunto de cuatro canales posee un límite máximo de 10,000 elementos para cada área de entrenamiento, o un cuadrado de 100 líneas por 100 columnas.

Un procedimiento común para la selección de las áreas de entrenamiento es el usar los datos de referencia disponibles para identificar las áreas que contienen las clases de información de interés. Estas áreas son también localizadas en los datos multiespectrales. Con esta información, nosotros seleccionamos entre tres y seis áreas de entrenamiento (de cinco a diez en conjuntos de datos con mucha variación) que contengan más de un tipo de cobertura y tomando cuidado de que cada tipo este incluido en al menos una de las áreas de entrenamiento (de preferencia en dos o más). Si solo se seleccionan tres áreas, cada una debe ser tan grande como sea posible, considerando las limitaciones del sistema de cómputo utilizado. Si se seleccionan más áreas, cada una puede ser más pequeña. Un criterio útil es el incluir rasgos fácilmente distinguibles en cada una de las áreas de entrenamiento para facilitar la correlación entre los datos de la imagen multiespectral y los datos de referencia. Para asegurar que las muestras de entrenamiento son representativas, estas deben estar distribuidas de

manera uniforme en la zona a clasificar; sin embargo, esto puede no ser posible si los datos de referencia disponibles son limitados.

Autoevaluación

1. Explique por qué es necesario analizar la calidad de los datos.
2. Mencione por lo menos dos métodos para examinar la calidad de los datos.
3. Mencione al menos dos problemas en la calidad de los datos que pueden encontrarse en los satélites Landsat.
4. Señale que tipo de correcciones geométricas pueden ser útiles en el análisis de datos Landsat.
5. Mencione una razón del por qué es necesario correlacionar los datos Landsat con datos de referencia.
6. Enumere al menos cuatro tipos de datos de referencia.
7. Explique por qué es necesario obtener muestras de entrenamiento.
8. Mencione dos aspectos que deben tomarse en cuenta en la selección de las áreas de entrenamiento en el método híbrido.

CAPITULO III. DEFINICION ESTADISTICA
DE LAS CLASES ESPECTRALES DE ENTRENAMIENTO

Al finalizar este capítulo, Usted sera capaz de:

1. Describir al menos dos trabajos que pueden elaborarse con el algoritmo de agrupamiento.
2. Conocer la regla empírica utilizada para determinar el número de grupos que deben ser solicitados en el algoritmo de análisis de conglomerados y explicar el razonamiento detras de esta regla.
3. Explicar porqué el analista asocia clases de agrupamientos con clases informacionales.
4. Utilizando un mapa resultado de un agrupamiento y los datos de referencia disponibles, describir el como asociar las clases del agrupamiento con las clases informacionales.
5. Dar un ejemplo de cuando es necesario aumentar el número de candidatos a clases de entrenamiento, obtenidas de un análisis de agrupamientos de las muestras de entrenamiento.
6. Describir, al menos, un método para visualizar las características espectrales de las clases de entrenamiento.
7. Senalar la ubicación del agua, de la vegetación verde y del suelo desnudo en una gráfica bi-espectral.
8. Dados dos pares de distribuciones unidimensionales, identificar el par mas separable con base en una mayor distancia estadística.
9. Nombrar las dos características de la distribución de probabilidad Gaussiana que determinan la distancia estadística entre las distribuciones.
10. Nombrar dos características deseables de las clases de entrenamiento.
11. Dado un diagrama de separabilidad y una lista de las identidades de cada una de las clases espectrales, describir la forma de seleccionar el conjunto de clases de entrenamiento para ser usadas en una clasificación.
12. Conocer la utilidad y limitaciones de las medidas de distancia estadística para predecir la precisión de la clasificación dado un conjunto determinado de clases de entrenamiento.

En el capítulo anterior describimos como seleccionar las muestras de entrenamiento utilizando los métodos supervisado, no supervisado e híbrido. Ahora discutiremos el como usar estas muestras para definir las clases espectrales de entrenamiento.

En el método supervisado, las clases de entrenamiento son automáticamente definidas a través del proceso de selección de muestras de entrenamiento para cada una de las clases de cobertura del terreno (clases informacionales). Todo lo que necesitamos hacer antes de clasificar el área de estudio es caracterizar las clases de entrenamiento para que el algoritmo de clasificación pueda usarlas. Dependiendo del tipo de clasificador empleado, esta caracterización se realiza en términos del vector de las medias y la matriz de covarianza de cada una de las clases de entrenamiento, o solo el vector de las medias. Este vector esta compuesto de los valores promedio de los datos en cada una de las bandas espectrales. la matriz de covarianza es una generalización multivariada de la varianza y es empleada para representar la dispersión multidimensional de los datos en cada clase de entrenamiento.

En los métodos no-supervisado e híbrido, nosotros debemos analizar las muestras de entrenamiento para encontrar grupos de elementos que sean similares espectralmente y que puedan emplearse como clases espectrales de entrenamiento. Primero debemos agrupar las muestras de entrenamiento para definir las clases candidatas de entrenamiento (en el método híbrido cada área de entrenamiento es analizada en forma separada). Posteriormente asociamos cada clase candidata de entrenamiento con la o las clases informacionales. Si nosotros encontramos que algunas clases informacionales no están representadas por al menos una clase candidata de entrenamiento, debemos de aumentar las clases candidatas de entrenamiento en este punto, añadiendo la o las muestras de entrenamiento apropiadas para cada una de las clases informacionales por medio del método supervisado. En seguida analizamos las clases candidatas de entrenamiento para ver como están relacionadas espectralmente una con otra. Podemos hacer esto graficando las características estadísticas de clases candidatas de entrenamiento y calculando la distancia estadística entre las clases. Las clases finales de entrenamiento son definidas eliminando o juntando las clases candidatas de entrenamiento apropiadas. Todos estos pasos son descritos en detalle en las siguientes secciones.

AGRUPACION DE LAS MUESTRAS DE ENTRENAMIENTO

El primer paso en la definición de las clases espectrales de entrenamiento a partir de las muestras de entrenamiento, es el análisis de agrupamientos o conglomerados, esto es identificar grupos naturales de elementos en las muestras. Cada elemento de las muestras de entrenamiento posee una ubicación en el espacio multispectral, en relación con todos los demas elementos de la muestra. Los elementos tienden a agruparse en este espacio tal y como se muestra en la figura III-1.

Los agrupamientos naturales solo se pueden visualizar en conjuntos de datos de una, dos o tres dimensiones. Para agrupar datos con mas dimensiones, y evitarnos una tediosa tarea, utilizamos el computador como herramienta de trabajo.

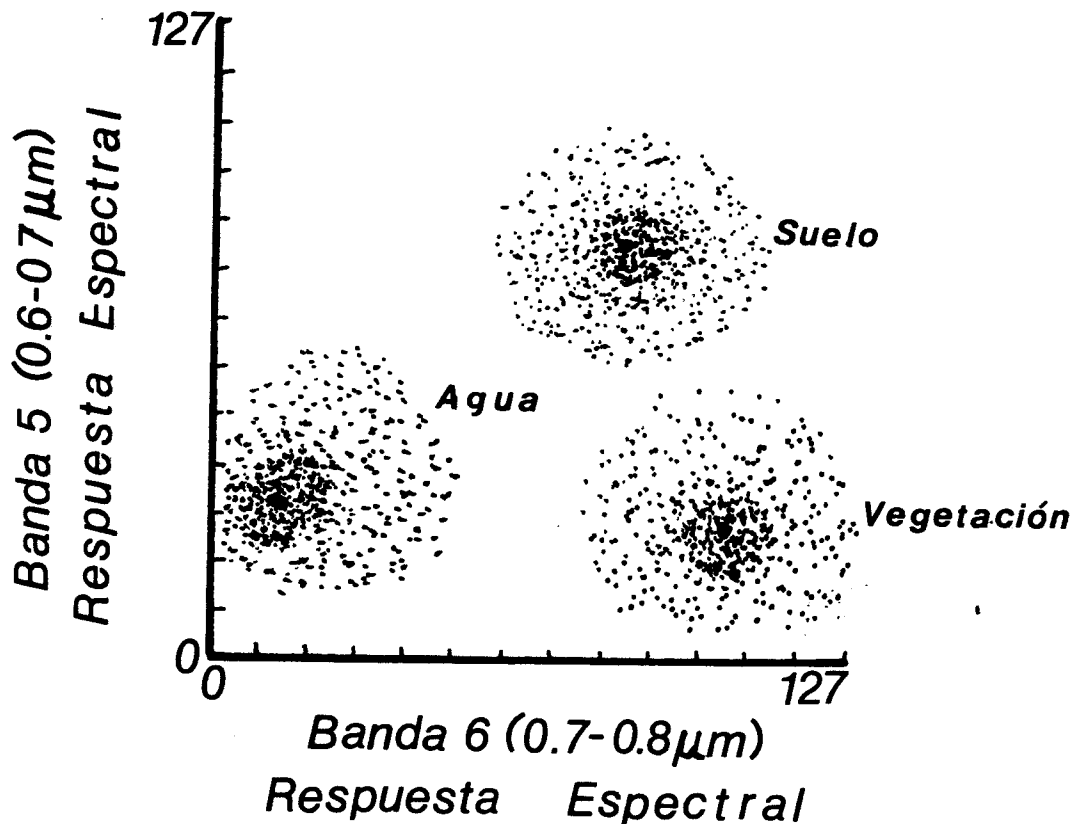


Figura III-1. Gráfica de las respuestas típicas del agua, suelo y vegetación en las bandas 5 y 6 del barredor multiespectral del satélite Landsat. Note como las respuestas espectrales de cada uno de estos tres grandes grupos de cobertura tienden a agruparse alrededor de un centro común.

¿Cómo puede el computador agrupar las muestras de entrenamiento? En LARSYS, la función de procesamiento (procesador) llamada CLUSTER utiliza el siguiente método para agrupar las muestras de entrenamiento (o las áreas de entrenamiento): El analista especifica el número de grupos deseados y el procesador asigna automáticamente el centro inicial de cada grupo en el espacio multidimensional (ver figura III-2). A continuación calcula la distancia euclídeana multidimensional entre cada punto de las muestras de entrenamiento y cada centro, y asigna cada elemento al grupo con el centro mas cercano. En seguida se determinan nuevos centros de los grupos calculando el vector de las medias de los

puntos asignados a los centro iniciales. El computador continúa el ciclo de cálculo de nuevos centros y reasignación de elementos hasta que el porcentaje de puntos que no son reasignados a un nuevo centro alcanza un valor conocido como "convergencia". Si especificamos un valor de convergencia menor que el de 100% especificado automáticamente por el programa, por ejemplo 98.5%, obtendremos un ahorro significativo en el tiempo de máquina utilizado sin afectar seriamente los resultados del análisis de conglomerados. Para mas información refierase a la sección 3.10 del libro de Swain y Davis.




Figura III-2. Secuencia de las iteraciones del procesamiento de agrupamientos: (a) Centros iniciales de los grupos, (b) y (c) Pasos intermedios, (d) Posición final de los centros.

El algoritmo de agrupamientos del tipo de CLUSTER es denominado un clasificador no-supervisado ya que agrupa los elementos con base en sus valores en las bandas multispectrales. Para la determinación de los agrupamientos, no se considera la posición de los elementos uno con respecto al otro (información espacial) o el tipo de cobertura del terreno. Este algoritmo agrupa a los elementos con valores espectrales similares en los datos multispectrales. Estos grupos naturales en las muestras de entrenamiento son denominados clases de agrupamiento o clases espectrales. En los métodos no-supervisado e híbrido, utilizamos estas clases como las clases candidatas de entrenamiento originales.

Cuando los datos de la escena son agrupados, estos presentan la tendencia a distribuirse en forma normal o Gaussiana. La figura III-3 muestra una distribución Gaussiana típica en una dimensión --comunmente llamada distribución en campana o curva normal--. La figura III-4 muestra una distribución Gaussiana en dos dimensiones. El hecho de que los agrupamientos de datos de percepción remota tiendan a distribuirse en forma Gaussiana es un aspecto importante ya que muchos de los algoritmos de clasificación empleados asumen una distribución de este tipo, esto es, que los valores de los datos en cada clase a clasificar se aproximan a una distribución Gaussiana.




Figura III-3. Distribución Gaussiana en una dimensión.




Figura III-4. Distribución Gaussiana en dos dimensiones.

A menudo, se necesita más de un grupo con distribución normal para representar a una clase informacional (tipo de cobertura). Por ejemplo, un cultivo agrícola puede mostrar una distribución multimodal (más de un pico) debido a las diferencias en el tipo de suelo, contenido de humedad, fechas de plantado, densidad de siembra, variedad de semillas o una combinación de estos factores. Para satisfacer la suposición de distribución normal, una distribución multimodal no-Gaussiana, como se muestra en la figura III-5 puede ser dividida en dos componentes Gaussianos, utilizando análisis de agrupamientos, tal y como se muestra en la figura III-6. Estos componentes son denominados comunmente "subclases

espectrales". El concepto de subclase espectral es muy importante ya que nos permite emplear un algoritmo de clasificación basado en una distribución Gaussiana, a pesar de que la distribución de las clases informacionales no lo sea. Esto se debe al hecho de que el clasificador se basa en clases espectrales y no en clases informacionales.




Figura III-5. Distribución multimodal no-Gaussiana.




Figura III-6. Distribución multimodal no-Gaussiana dividida en dos componentes.

Cuando utilizamos la función de procesamiento CLUSTER, nosotros debemos especificar el número inicial de grupos en los que los datos deben agruparse. La experiencia muestra que la mayoría de los tipos de cobertura contiene al menos dos subclases. Como regla empírica nosotros solicitaremos al procesador CLUSTER al menos dos veces el número de clases informacionales presente en el área de estudio. Si estas son muy generales, debemos especificar tres subclases por cada clase informacional. Si pedimos un número insuficiente de grupos, la varianza de estos será muy grande y será difícil separar las clases de entrenamiento resultantes. Si por el contrario especificamos un número muy alto de agrupamientos iniciales, las varianzas serán pequeñas, pero será difícil identificar las clases de entrenamiento resultantes. Sin embargo, el problema de tener demasiados grupos puede ser solucionado eliminando o juntando grupos, mientras que cuando contamos con pocos grupos, a menudo es necesario repetir todo el proceso. Un "adecuado" número de grupos, como el de la regla del doble de grupos, puede resolver estos conflictos. Sin embargo, en algunos casos será necesario especificar un número diferente de grupos después de examinar los resultados del proceso de agrupamiento, realizado por el CLUSTER.

El procesador de CLUSTER imprime los valores de media y desviación estandar de las clases de agrupamiento. Las varianzas muestran la dispersión de los datos en cada canal. Si algunas clases presentan varianzas muy altas con respecto a otras clases, será conveniente repetir el proceso especificando un numero mayor de grupos.

El procesador CLUSTER también ofrece al analista una herramienta para determinar si los resultados son razonables: es decir un histograma. Cada histograma muestra la distribución de los valores de los datos en cada canal para cada clase. Puesto que el clasificador supone una distribución Gaussiana, es importante examinar estos histogramas para asegurarse de que esta suposición es satisfecha al menos aproximadamente por los datos. Esto puede hacerse analizando si los histogramas presentan o no una distribución normal*. Si un número importante de histogramas violan significativamente la suposición de distribución Gaussiana, nosotros debemos repetir el paso de agrupamiento de los datos con mas clases.

Cuando se calculan los parámetros estadísticos que describen las clases, nosotros debemos asegurar que existe un número adecuado de observaciones sobre las cuales basar los cálculos. Esto significa que debemos contar con suficientes elementos en cada clase de agrupamiento. Para cada grupo se requiere como mínimo un elemento mas que el número de bandas espectrales en el barredor multiespectral. Sin embargo, para asegurar que los elementos sean representativos estadísticamente de la clase caracterizada, debemos utilizar al menos 10 veces mas elementos que el número de bandas para caracterizar cada grupo, $(10 \times n)$ donde n es el número de bandas o canales.

ASOCIACION DE LAS CLASES CANDIDATAS DE ENTRENAMIENTO CON LAS CLASES INFORMACIONALES

Es posible imprimir un mapa de las clases de agrupamiento a las que cada elemento fue asignado durante el proceso de agrupamiento. Los elementos asignados al mismo grupo son representados por el mismo símbolo. Así, las áreas en la escena que son espectralmente homogéneas (en las bandas espectrales empleadas) se mostrarán con el mismo símbolo. De esta manera, el proceso de agrupamiento funciona como un paso de realzado de límites, permitiéndonos identificar mas fácilmente, las áreas homogéneas espectralmente en los datos agrupados a partir de varios canales que en datos de un solo canal

* Un punto importante a considerar es que las funciones de distribución representadas por los histogramas, son funciones de densidad marginales. No hay ninguna garantía, a pesar que las distribuciones marginales sean razonablemente Gaussianas, de que las funciones de distribución sean Gaussianas. Si la distribución de densidad marginal es no-Gaussiana, entonces la función de densidad sera no-Gaussiana.

espectral. Mapas de agrupamientos serán utilizados en esta sección para ayudar a relacionar las clases de agrupamiento (clases candidatas de entrenamiento) con las clases informacionales.


No existe una correspondencia de uno a uno entre las clases informacionales y las clases de agrupamiento. Hay que recordar que una clase informacional es un tipo de cobertura del terreno, mientras que las clases de agrupamiento son grupos de elementos que son similares espectralmente. Tal y como se muestra en la figura III-7a, puede existir una correspondencia de uno a uno entre ambos tipos de clases. Sin embargo, es mas comun que varias clases de agrupamiento representen el mismo tipo de cobertura (clase informacional) como se muestra en la figura III-7b. En ocasiones, diferentes clases informacionales se asociarán con una misma clase de agrupamiento (figura III-7c). Esta última situación nos indica que las clases informacionales son similares espectralmente. Para separar las clases informacionales en diferentes grupos será necesario repetir el proceso de agrupamiento solicitando un numero mayor de grupos iniciales.

Para identificar los grupos obtenidos, nosotros utilizamos todos los datos de referencia disponibles para obtener una correlación confiable entre las clases de agrupamiento y los tipos de cobertura. Es importante señalar que, si en esta etapa se realiza una identificación errónea, esta será acarreada hasta la clasificación final, resultando en mapas y estimaciones de superficie erróneos. El proceso de asociar clases de agrupamientos con clases informacionales es tedioso y lento, pero este paso es muy importante para asegurar que estamos entrenando adecuadamente al clasificador.


En ocasiones, los datos de referencia son fotografías aéreas. Es posible emplear un proyector de transparencias para superponer la fotografía de 9 por 9 pulgadas con el mapa resultado del agrupamiento. Simplemente modificando la distancia entre el proyector y la pantalla podemos proyectar la transparencia a la escala del mapa y si los datos del barredor han sido corregidos geoméricamente, obtendremos una concordancia adecuada. Con un proyector de diapositivas de 2 por 2 pulgadas es posible obtener mejores resultados.

Mapas topográficos del Servicio Geológico de los Estados Unidos son tambien utiles para propósitos de localización. Esto es especialmente cierto con impresiones de datos corregidos geoméricamente y reescalados a la escala de los mapas. Las impresiones del computador pueden superponerse con los mapas y analizarse en una mesa de luz.


Un instrumento que facilita el proceso de superposición, es el "Zoom Transfer Scope", este aparato utiliza un sistema de lentes para ajustar las imágenes de dos mapas para hacerlos superponer. Nosotros podemos observar el mapa de agrupamientos y las fotografías



(a)



(b)



(c)

Figura III-7. Ejemplos de las relaciones que pueden presentarse entre diferentes clases informacionales y clases de agrupamiento.

aéreas superpuestas e identificar los grupos confiable y rápidamente.

Durante el análisis hay que tener en mente varios puntos. Uno es que si una clase de agrupamiento aparenta representar más de una clase informacional, la primera debe ser identificada de esta manera. Otro aspecto es que, en el método híbrido, cada área de entrenamiento es procesada independientemente. Por lo tanto, los símbolos en el mapa de una área de entrenamiento no corresponden necesariamente a la misma clase informacional en otra área de entrenamiento.

AUMENTO DE LAS CLASES CANDIDATAS DE ENTRENAMIENTO

Después de terminar la etapa de asociar las clases de agrupamiento con las clases informacionales, es muy importante verificar el que todos los tipos de cobertura del terreno conocidos en la escena estén representados en el conjunto de muestras de entrenamiento. Si estamos utilizando el método no-supervisado, el muestreo sistemático o al azar pudo haber obviado clases informacionales poco frecuentes. Ahora bien, en los métodos híbrido y supervisado nosotros podemos haber pasado por alto algunas clases informacionales, tales como nubes o sombras de nubes, las cuales ocurren con cierta frecuencia en los datos multiespectrales pero no aparecen en los datos de referencia.

Aun cuando no estemos interesados en identificar elementos asociados a estas clases, debemos incluir clases de entrenamiento para representarlas. De lo contrario, el clasificador se verá forzado a cometer un error al clasificar elementos de estas clases. Por ejemplo, las sombras de nubes pueden clasificarse como agua, si no proporcionamos al clasificador clases de entrenamiento de sombra de nubes. Esto puede llevarnos a cometer un error muy serio si estamos realizando la clasificación para mapear cuerpos de agua.

Podemos definir las clases de entrenamiento para las clases no incluidas utilizando el método supervisado. En LARSYS la descripción estadística de las clases tal y como se define en el método supervisado, se puede obtener por medio del procesador STATISTICS. Este procesador, requiere como datos de entrada los valores de líneas y columnas de las áreas para las cuales se desea calcular los valores estadísticos. El programa lee los valores de los elementos incluidos en el área especificada y calcula el vector de las medias y la matriz de covarianza de esos elementos.

En el método híbrido, nosotros podremos haber seleccionado las áreas de entrenamiento de tal forma que incluyeran todas las clases informacionales presentes en el área, de esta forma no tendremos que utilizar el método supervisado para definir clases de entrenamiento para estas clases adicionales. Sin embargo, cuando esas clases son espectralmente únicas, tal y como sucede con las nubes, es más adecuado utilizar el método supervisado para caracterizar esa clase. Cuando elementos de nubes son procesados junto con vegetación por el

análisis de agrupamiento, el procesador tiende a identificar varios grupos espectrales entre las nubes y la vegetación, cada uno con muy pocos elementos y sin estar relacionado realmente a alguna clase informacional.

Otro aspecto a considerar al aumentar las clases candidatas de entrenamiento, es el hecho de que algunos agrupamientos pueden estar representando más de una clase informacional. Como se mencionó anteriormente, esto implica que dichas clases son similares espectralmente. Para solucionar este problema, nosotros podemos repetir el paso de análisis de agrupamientos, solicitando un número mayor de grupos. En algunos casos, sin embargo, no es necesario hacer esto de nuevo para todas las muestras de entrenamiento. Si es posible identificar en los datos del barredor, elementos pertenecientes a la clase mixta, podemos seleccionar únicamente elementos en ese grupo para ejecutar de nuevo el proceso de agrupamiento. Por ejemplo, nosotros podemos haber notado que los bosques caducifolios y bosques de coníferas son similares espectralmente y fueron asociados a la misma clase de agrupamiento. Si podemos identificar elementos de ambos tipos de bosque en los datos del barredor, podemos agrupar esos elementos para obtener clases separadas de bosque caducifolio y bosque de coníferas.

REPRESENTACION VISUAL DE LAS CLASES CANDIDATAS DE ENTRENAMIENTO

Ahora nosotros debemos tener una representación de las clases candidatas de entrenamiento del conjunto de datos del barredor multiespectral. Varias de estas clases pueden ser similares espectralmente. Si estas clases similares representan a la misma clase informacional, podemos combinarlas para crear una sola clase. Si por el contrario, representan diferentes clases informacionales nosotros podemos eliminar algunas de las clases candidatas de entrenamiento, con el objeto de reducir el número de clases de entrenamiento, para evitar crear confusión en la clasificación. Generalmente, nosotros reducimos el número de clases de entrenamiento, ya que esto reduce el tiempo de máquina empleado para realizar la clasificación y simplifica la interpretación de los resultados. Al hacer esto, debemos tener cuidado de que las clases de entrenamiento finales sean todavía representativas del conjunto de datos de barredor.

En primer término, para reducir el número de clases candidatas de entrenamiento, es muy útil poder visualizar las características espectrales de todas las clases candidatas de entrenamiento. El procesamiento de MERGESTATISTICS posee como uno de sus resultados de salida una gráfica en dos dimensiones llamada "bi-spectral plot". Graficado en unos de los ejes se encuentran los valores de la media en un canal de todas las clases candidatas de entrenamiento. En el otro eje, se grafican los valores medios de las clases en otro canal. Para poder utilizar información de más de dos canales en la gráfica bi-espectral, las medias de las clases en un determinado conjunto de canales pueden ser promediadas y graficadas en un eje, hacemos lo mismo para otro conjunto de canales graficándolo en el

otro eje. Por ejemplo, con datos Landsat se promedian los valores de las medias de las clases de los dos canales infrarrojos y se grafican en un eje. Los valores de las bandas visibles se promedian y grafican en el eje restante. La razón del porqué se promedian los valores de esta manera, está basada en la observación de que las respuestas en los dos canales visibles están muy correlacionadas, así como las respuestas en los canales infrarrojos (esto se puede observar comparando las imágenes de las dos bandas visibles y las de las dos bandas infrarrojas de cualquier imagen Landsat). Con cualquier combinación de canales utilizada en la gráfica bi-espectral, la información de un espacio multidimensional puede ser representada en dos dimensiones. El resultado final es una gráfica que permite la visualización de las medias de todas las clases candidatas de entrenamiento.

Otra forma de representar a las clases candidatas de entrenamiento es una gráfica espectral de las medias calibradas. Esta gráfica puede ser utilizada adecuadamente con datos de dimensiones pequeñas tales como los de Landsat (cuatro bandas) o de alta dimensionalidad tales como los datos del Skylab (trece bandas). En contraste, es mucho más difícil emplear adecuadamente la representación bi-espectral con datos con una dimensionalidad más grande que los de Landsat. Antes de dibujar las gráficas espectrales de medias calibradas, los valores de las clases en cada una de las bandas deben ser calibradas de tal manera que un determinado valor de radianza en cada banda produzca el mismo valor medio. Una vez que esta calibración se realiza, las medias de las clases pueden graficarse contra las bandas espectrales tal y como se muestra en la figura III-8.

CALCULO DE LA DISTANCIA ESTADISTICA ENTRE LAS CLASES CANDIDATAS DE ENTRENAMIENTO

A pesar de que en este punto es posible visualizar y comparar todas las clases candidatas de entrenamiento, esta comparación estaría basada solo en las medias de las clases. Antes de realizar cualquier decisión acerca de cuales clases juntar y cuales eliminar, encontraremos útil el contar con la información sobre la dispersión o variabilidad de cada clase.

Otra razón importante del porqué es necesario tomar en cuenta la dispersión de los datos en cada clase es para tener una indicación de la probabilidad de clasificación correcta antes de realizar la clasificación. Si encontramos que existe una confusión considerable entre las clases informacionales, debemos repetir el paso de análisis de agrupamientos en las áreas de entrenamiento, solicitando un número diferente de grupos. Por otro lado, es posible seleccionar áreas de entrenamiento adicionales (en el método híbrido) con el objeto de mejorar las diferencias entre las clases que ya tenemos.

El calcular la separabilidad de las clases de agrupamiento puede ayudarnos para determinar que grupos son similares y puede




Figura III-8. Gráficas espectrales de las medias calibradas de las áreas de entrenamiento de la imagen Landsat, de la zona del condado de Monroe, Indiana.

servir como una indicación de la probabilidad de clasificación correcta.

Para entender como se realiza esto, primero debemos discutir el concepto de "distancia estadística". La figura III-9 muestra dos ejemplos de distribuciones uni-dimensionales. Intuitivamente nosotros sabemos que la "distancia" entre las distribuciones del caso B son mayores que las distribuciones del caso A. La distancia entre dos distribuciones de probabilidad Gaussiana depende no solo de la distancia entre sus medias, sino también de la dispersión de los datos. La figura III-10 ilustra este hecho. La distancia entre las medias de ambas distribuciones es igual en ambos casos, pero puesto que la variación en el caso B es menor que en el caso A, tenemos una distancia estadística mayor en el caso B.




Figura III-9. Dos pares de funciones de distribución en un dimensión. La distancia estadística entre las funciones en el caso A es menor que en el caso B.




Figura III-10. Los dos pares de distribuciones que se muestran en la figura se encuentran equidistantes, pero la menor varianza en $P_3(\lambda)$ y en $P_4(\lambda)$ es la causa de que estas presenten una mayor distancia estadística.

En una gráfica de dos dimensiones, las funciones de distribución pueden representarse como elipses (figura III-11). En tres dimensiones o más, tal y como sucede en los datos Landsat, las funciones de distribución se representan por elipsoides (superficies en forma de esferóides con igual probabilidad en el espacio de medición). Tal y como sucede en el caso uni-dimensional, la distancia estadística en dos o más dimensiones se estima por la sobreposición de las distribuciones. Como se muestra en la figura III-11, la sobreposición es mayor debido a la orientación de una de las elipses. Por lo tanto, podremos anticipar que la precisión de la clasificación del caso B será menor.

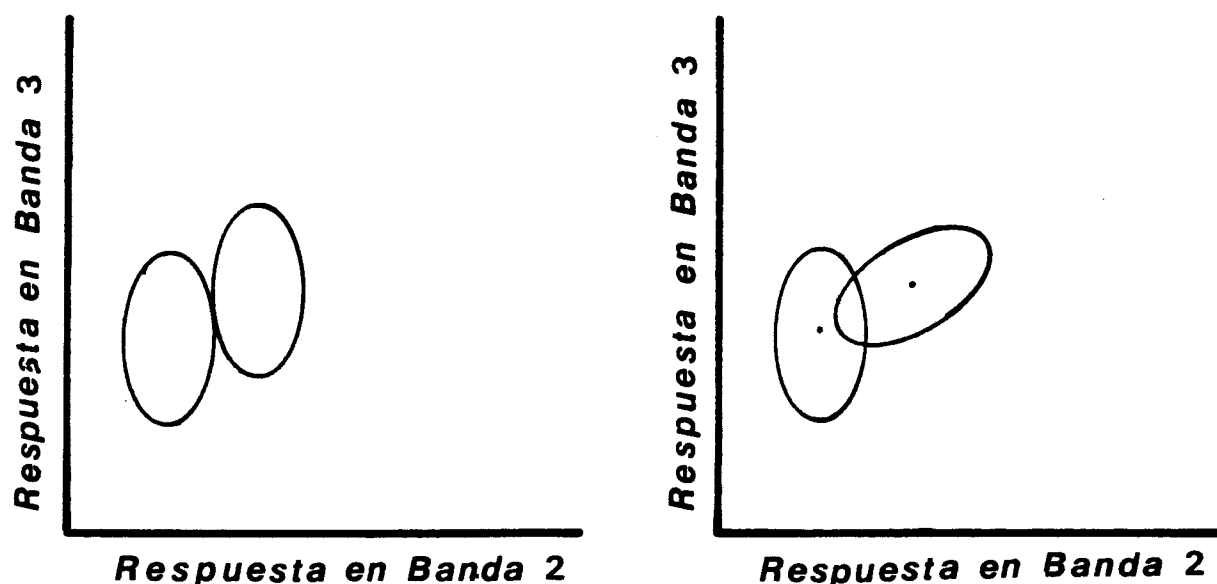


Figura III-11. Elipses representativas de clases de entrenamiento.

La divergencia transformada (D_t), es una medida multivariada de la distancia estadística. Existen otras medidas de esta distancia, pero la divergencia transformada, estima adecuadamente la probabilidad de clasificación correcta entre pares de clases. Al graficar los resultados experimentales de la probabilidad de clasificación correcta contra la divergencia transformada de clases de entrenamiento, obtendremos una gráfica como la de la figura III-12. Es importante notar que los pares de clases con valor de divergencia transformada alto (D_t) poseen una precisión de clasificación alta (P_c), aunque la relación no es estrictamente lineal. Esta gráfica puede auxiliarnos en la determinación del valor mínimo de divergencia transformada aceptable entre pares de clases. De acuerdo a la figura III-12, para obtener una precisión del 85%, las clases de entrenamiento finales deben poseer un valor de divergencia entre 800 a 1800. Las clases con valor de D_t de 800 presentarán una precisión del 85% en raras ocasiones. Por otro lado

las clases con valores de 1800 tendrán una precisión de 85% la mayoría de las veces. No obstante podemos estar tentados a requerir un umbral muy alto, mientras mayores sean los valores de divergencia transformada, solo las clases mas generales de cobertura (por ejemplo, "agricultura" en lugar de "maiz", "soya", "trigo", etc.) podrán ser separables. Por lo tanto es necesario encontrar un balance entre el nivel de detalle deseado y los valores mínimos de divergencia transformada permitibles, de tal manera que se pueda obtener una precisión aceptable la mayoría de las veces para las clases informacionales. Mas detalles sobre las medidas de distancia estadística se pueden encontrar en las secciones 3.7 y 3.8 del libro de Swain y Davis.

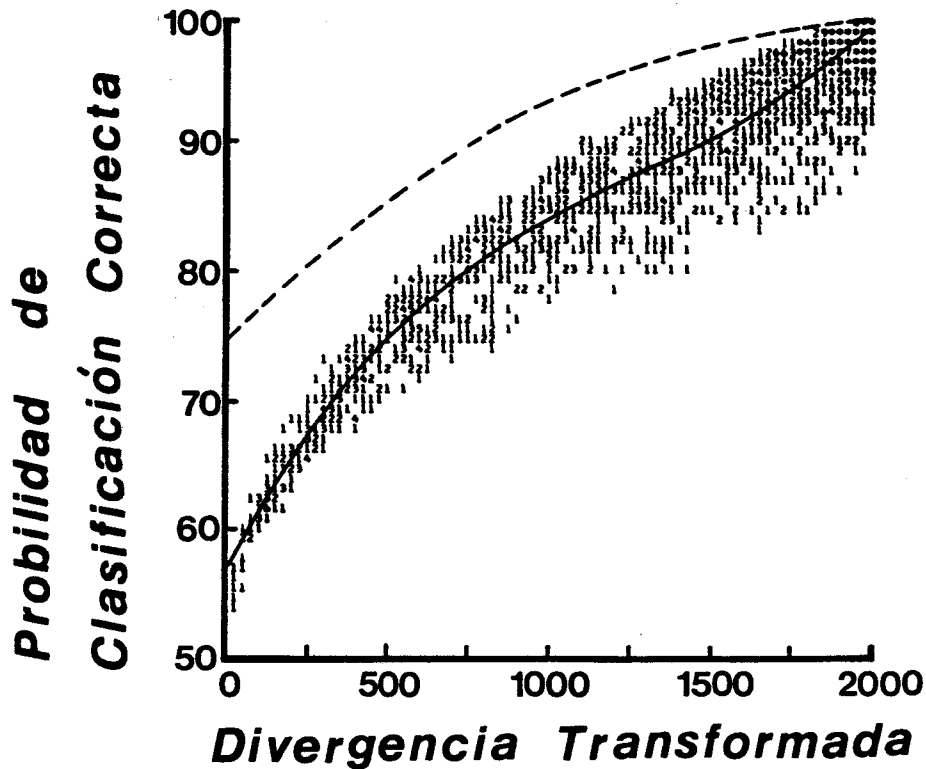


Figura III-12. Valores observados de la probabilidad de clasificación correcta y el valor de divergencia transformada.

En LARSYS, el procesador llamado SEPARABILITY permite calcular la divergencia transformada entre pares de clases. El analista utiliza típicamente la información del procesador SEPARABILITY y la gráfica bi-espectral, incorporando a esta última los resultados del cálculo de la separabilidad. Esto se hace como se muestra en la figura III-13. Una línea continua entre dos clases indica que la divergencia transformada entre ambas clases es menor a 1000. Una línea punteada entre dos clases indica que el valor de divergencia se encuentra entre 1000 y 1500. La divergencia entre las clases restantes es mayor de 1500 en este ejemplo.

AVERAGE PEAN FOR INFRARED BANDS (CHAN. 3 & 4)




Figura III-13. Gráfica bi-espectral con la información de separabilidad de las clases.

La información de separabilidad puede ser empleada también en las gráficas de valores espectrales medios, de la misma forma que se empleo con la gráfica bi-espectral. Además, la forma de las curvas de las clases nos proporciona mas información respecto a la separabilidad de las clases. En ocasiones, el valor de divergencia transformada entre dos clases puede ser muy bajo a pesar de que las clases sean separables. Cuando esto sucede, ambas clases deben poseer valores medio semejantes pero la forma de las curvas debe variar considerablemente, como se muestra en el ejemplo de la figura III-14.




Figura III-14. Ejemplo de gráficas espectrales de medias calibradas de dos clases separables que presentan un valor de divergencia transformada bajo.

REFINAMIENTO DE LAS CLASES ESPECTRALES DE ENTRENAMIENTO

El paso final en la definición de las clases espectrales de entrenamiento es el refinamiento de estas clases candidatas con el fin de obtener un conjunto final de clases de entrenamiento. Hasta ahora, la determinación de estas clases ha incluido el agrupamiento de las muestras de entrenamiento (o áreas de entrenamiento), asociar

las clases de agrupamiento con las clases informacionales (tipos de cobertura), aumentar las clases de agrupamiento cuando sea necesario, calcular la distancia estadística de las clases de agrupamiento (clases candidatas de entrenamiento), calcular la divergencia transformada para obtener una medida de la distancia entre pares de grupos, y la incorporación de esta información en una gráfica bi-espectral. El siguiente paso será el decidir cuales de las clases candidatas de entrenamiento deben ser agrupadas para formar clases espectrales de entrenamiento, que clases candidatas pueden ser empleadas directamente y cuales deben ser eliminadas. En el siguiente ejemplo, nosotros utilizaremos la gráfica bi-espectral con la asociación de las clases espectrales con clases informacionales y los valores de divergencia transformada para hacer estas decisiones. Posteriormente discutiremos como las curvas calibradas de medias espectrales, las observaciones sobre la normalidad de clases tal y como aparecen en los histogramas y el número de puntos en cada clase candidata de entrenamiento pueden ser empleadas para resolver algunas dificultades.

Existen varias formas de abordar la tarea de seleccionar las clases espectrales de entrenamiento finales a partir de las clases candidatas de entrenamiento. El objetivo final es el de obtener clases de entrenamiento representativas de las clases informacionales presentes en el área y que sean separables entre sí. A continuación presentaremos dos métodos con diferente orientación, para la selección de las clases finales de entrenamiento además ofreceremos una guía de como solucionar algunos problemas que en ocasiones suelen ocurrir.

El primer método es conocido como el de "combinación" o "unión". En éste, las clases candidatas de entrenamiento cuya distancia estadística es menor que el umbral mínimo previamente establecido, son unidas para formar una sola clase. Este método se basa únicamente en los datos de divergencia transformada para unir todas o casi todas las clases candidatas de entrenamiento en grupos de clases conectados unos con otros. La identidad de las clases se emplea para indicar que porción de la gráfica (y por tanto que porción del espacio multidimensional) pertenece a cada clase informacional.

A pesar de que la identidad de las clases candidatas de entrenamiento se considera al momento de decidir juntar algunas clases, no se requiere que las clases candidatas que deseamos unir posean la misma identidad. Por ejemplo, en la figura III-15 a los pares de clases cuya divergencia transformada es menor a 1000 se dibujó una línea continua entre ellas, para los pares con valor de divergencia entre 1000 y 1500 se dibujó una línea punteada. De este diagrama podemos escoger dos grupos, juntando las clases con los símbolos R, S, /, E y U (los cuales representan bosque), y las clases con los símbolos +, D, T, =, N, F y A2 (representando agricultura). Es importante notar que la clase con el símbolo N identificada como bosque, fue unida al grupo agricultura por ser mas similar a estas clases y estar rodeada por ellas. Es posible que la

clase con el símbolo N fue identificada erróneamente como bosque; es pues recomendable verificar la identidad de las clases cuando este tipo de problemas aparecen. En muchas ocasiones concluiremos que esta clase "anómala" es mas parecida a las clases a las que fue unida, que a las clases informacionales a las que parecía pertenecer inicialmente. Sin embargo, si la clase con el símbolo N es claramente una clase de bosque, no es recomendable el unirla a las clases de agricultura.

El segundo método de selección de clases de entrenamiento es conocido como el de "eliminación". En este método, las clases candidatas de entrenamiento son seleccionadas en forma individual o en grupo para disminuir la varianza de las clases de entrenamiento finales, para lograr esto, las clases en los límites de las clases informacionales son eliminadas. Regresando a la figura III-15, con este método las clases con los símbolos R, S, / y U representarán a los bosques, y las clases con los símbolos +, D, T, = y F representarán la clase agricultura. Las clases E, N y A2 son eliminadas. Como resultado de este método, las clases de entrenamiento para el bosque y agricultura se encuentran más separadas y son más fácilmente distinguibles entre sí y entre otras clases. Llevado hasta el extremo, el método de eliminación nos lleva a un mayor número de clases de entrenamiento mas específicas (pero no necesariamente más representativas). Otro ejemplo puede ser el escoger las clases R y S como una variedad de bosque y la clase U como otra variedad de bosque. Las clases / y E serían eliminadas.

La siguiente lógica puede ayudarnos a decidir cuando eliminar o no alguna clase: Las características espectrales de las clase de cobertura del terreno son descritas mas adecuadamente por una nube de puntos que por un solo punto. Cuando una nube es descompuesta en subclases por el proceso de agrupamiento, una o mas de las subclases estarán compuestas de puntos cercanos al límite de la nube. Estos puntos, los cuales no son muy similares a los puntos del centro de la nube (los que representan mas adecuadamente a la clase de cobertura), no representarán adecuadamente a la clase informacional en cuestión. Además, es posible que esta subclase en el limite se confunda con mas subclases de diferente identidad. Cuando esto sucede, la eliminación de las subclases en los limites de las nubes es razonable y válida.

Podemos decir que con el método de unión, uno esta mas interesado en obtener clases de entrenamiento representativas, mientras que el método de eliminación busca obtener clases de entrenamiento separables. En la práctica es necesario considerar ambos conceptos, representatividad y separabilidad. Comunmente, el analista utilizará ambos metodos para obtener el mejor resultado en representación y separabilidad.

Hasta este punto nosotros hemos considerado ejemplos relativamente sencillos. Desafortunadamente, la mayoría de los

análisis presentan algunos problemas, y el proceso de decisión no es sencillo. En el ejemplo anterior al seleccionar las clases de entrenamiento para bosque y agricultura, tuvimos que decidir si la clase con el símbolo E debía de ser eliminada o no. En el método de unión la conservaríamos y uniríamos a las clases R, S, / y U ya que de otra manera degradaríamos la representatividad de la clase bosque. En el método de eliminación, eliminaríamos esta clase para realzar la separabilidad de las clases propuestas. Basándonos en la información de separabilidad y la gráfica bi-espectral es difícil decidir que método emplear. Afortunadamente, nosotros podemos utilizar información adicional la cual nos ayudará a decidir entre eliminar esta clase o unirla a otras. Por ejemplo, podemos preguntarnos: ¿cuántos elementos posee esta clase? ¿Su identidad está claramente definida? ¿La distribución de los valores en el histograma es claramente Gaussiana? ¿Qué tan grande son las varianzas en las bandas espectrales? Las respuestas a estas preguntas nos darán un índice de la calidad de las clases de entrenamiento. Se justificará entonces eliminar una clase con un número reducido de elementos, varianzas grandes y cuya identidad no haya sido establecida claramente, por otro lado no será adecuado eliminar una clase con un número grande de elementos, varianzas pequeñas e identidad bien definida.

Las gráficas espectrales calibradas pueden auxiliarnos para decidir cuando unir o eliminar alguna clase. Por ejemplo, si la curva para la clase E posee una forma claramente distinta de las clases de agricultura vecinas y es además muy semejante a las curvas de las clases de bosque, nos inclinaremos por unir la clase E al grupo de bosque en lugar de eliminar esta clase. Si la forma de la curva de la clase E se parece tanto a la clase bosque como a la clase agricultura, entonces será adecuado eliminar esta clase.

En ocasiones, pueden ocurrir situaciones más complicadas con las clases informacionales en las que estamos interesados y el conjunto de datos multiespectrales. Puede suceder que diferentes clases informacionales se confundan una con la otra. En la figura III-15, las clases \$, M, C, V, O, L y G están conectadas con la clase O, M y L las cuales se identificaron como áreas residenciales mientras que \$, C, V y G se identificaron como suelo y agricultura. El primer paso en estos caso es verificar la identidad de las clases. Suponiendo que esta sea correcta, refinaremos las clases de entrenamiento para aumentar su separabilidad. Este refinamiento es particularmente adecuado si varias clases no poseen distribución Gaussiana, presentan varianzas grandes o su identidad no esta claramente definida. El paso de refinamiento puede consistir en repetir el paso de análisis de agrupamientos de las áreas de entrenamiento, solicitando más grupos, o seleccionar áreas de entrenamiento adicionales y someterlas al análisis de agrupamientos. Esto último será recomendable si la representatividad de las clases de entrenamiento es cuestionable. Cuando encontramos problemas en las clases de entrenamiento, es recomendable efectuar este refinamiento. Sin embargo, hay que reconocer que si los valores digitales de reflectancia de los elementos de diferentes tipos de

cobertura son similares, ningún trabajo de refinamiento logrará que estas sean clases menos similares y por tanto, no podemos esperar que el proceso de refinamiento conduzca siempre a una mayor separabilidad en los tipos de cobertura.

Cuando el paso de refinamiento no sea exitoso, debemos considerar qué tipo de errores en la clasificación son o no aceptables. Por ejemplo, suponiendo que estamos interesados en clasificar áreas urbanas y encontramos que las clases candidatas de entrenamiento identificadas como urbanas son similares a las clases candidatas de entrenamiento de la clase agricultura. Decidiremos que, para nuestros propósitos, el error de clasificar algunas áreas de agricultura como urbanas no será muy grave, mientras que el clasificar algunos puntos de zonas urbanas como agricultura será desastroso. En este caso, podemos decidir eliminar de los siguientes pasos del análisis, la clase identificada como agricultura.

Es apropiado decir entonces, que el proceso de selección de clases de entrenamiento es el proceso de decidir que porciones del espacio multidimensional serán clasificadas. En el ejemplo anterior, nosotros decidimos nombrar a una parte del espacio multidimensional como urbano. Otro criterio que podemos emplear es examinar cuáles de las clases informacionales son más predominantes en el espacio multidimensional. Si la clase urbana que se confunde con la clase agricultura en el ejemplo anterior, está rodeada (en el espacio multidimensional) por clases de agricultura, la mejor decisión será el eliminar la clase urbana y mantener las clases de agricultura.

En ocasiones estaremos tentados a mantener una clase de entrenamiento que posea un número menor de elementos que el mínimo requerido, debido a que pensamos que esta es una clase informacional importante. Sin embargo, debemos considerar muy seriamente el retener esta clase, ya que es poco probable que los elementos en esa clase de entrenamiento representen adecuadamente a la clase informacional. Además, existe una posibilidad muy alta de que la matriz de covarianza de esa clase sea singular. Si esto último sucede, esta clase no puede ser empleada en muchos clasificadores y será inevitable su eliminación. Una mejor alternativa será el obtener más áreas de entrenamiento las cuales se crea que contienen elementos de esta clase informacional. Si esto no es posible, los resultados de la clasificación producida con esta clase de entrenamiento deben ser analizados cuidadosamente para garantizar que las clases "no satisfactorias" no han producido resultados inadecuados. Si en efecto, nosotros notamos este tipo de problemas, tendremos que eliminar dicha clase de entrenamiento.

Anteriormente contábamos con la descripción estadística de las clases candidatas de entrenamiento que aparecían en la gráfica bi-espectral. Antes de poder realizar la clasificación basada en las nuevas clases espectrales de entrenamiento, obtenidas a partir de los procesos de combinación y eliminación de clases candidatas de entrenamiento, debemos obtener la descripción estadística de las nuevas clases. Puesto que la mayoría de los clasificadores se basan

en la suposición de que la distribución de las clases es del tipo Gaussiano (definido por el vector de las medias y la matriz de covarianza de los grupos de muestras de entrenamiento), debemos obtener el mismo tipo de descripción estadística, recalculando los vectores de las medias y las matrices de covarianza para cada uno de los nuevos grupos de elementos. Cuando el grupo de elementos que componen la nueva clase de entrenamiento espectral es el resultado del método de unión, el cálculo de las nuevos descriptores estadísticos es denominado "unión de las estadísticas" de las clases espectrales candidatas de entrenamiento.

Después de obtener los vectores de las medias y las matrices de covarianza de las nuevas clases espectrales de entrenamiento, debemos verificar su separabilidad con el objeto de contar con una indicación de la probabilidad de clasificación correcta utilizando este nuevo conjunto de estadísticas. En LARSYS esta medida se obtiene con el procesador SEPARABILITY.

Es importante notar que al satisfacer un umbral en los valores de divergencia transformada, solo estamos garantizando el grado final de diferencia espectral entre las clases y que existe una cierta probabilidad de distinguirlas entre sí. Esto no significa que sean representativas, --nosotros como analistas debemos asegurar este aspecto. La representatividad está en función de las muestras de entrenamiento seleccionadas, la precisión en la identificación de las clases de agrupamiento y el número de clases de agrupamiento (y de tipos de cobertura en el terreno asociadas a las clases de agrupamiento) que sobrevivieron al paso de selección de clases. A pesar de que nosotros estemos seguros de la representatividad, separabilidad y precisión en la identificación de las clases, pueden ocurrir errores en la clasificación. Nosotros solo podemos optimizar los tres criterios, realizar la clasificación y, basados en los resultados obtenidos, determinar si la clasificación es aceptable o no lo es.

En caso de obtener resultados inaceptables, es necesario repetir alguno de los pasos anteriores, desde la adquisición de nuevos datos del barredor hasta la selección de nuevas clases de entrenamiento. Como mencionamos anteriormente, aunque el análisis aparenta ser un proceso de pasos en secuencia lineal, en realidad es una secuencia iterativa en donde los resultados de cada paso son cuidadosamente revisados y en ocasiones repetido antes de continuar al siguiente paso del análisis. El punto de selección de clases de entrenamiento es particularmente iterativo ya que una clase de entrenamiento recién formada, es seleccionada después de revisar la separabilidad entre las otras clases de entrenamiento, para después proceder a la clasificación. Comúnmente, nosotros realizaremos varios intentos de selección de clases de entrenamiento antes de obtener un conjunto adecuado de estas.

Un punto que debe estar claro ahora es que no existe un método único y correcto para realizar un análisis de datos multiespectrales. Conforme Ud. entienda los conceptos de

reconocimiento de patrones y obtenga experiencia como analista, desarrollará nuevos métodos para el análisis de los datos.

Autoevaluación

1. Describa dos pasos que puede ejecutar el proceso de análisis de agrupamientos.
2. Mencione la regla empírica que se utiliza para determinar el número inicial de clases de agrupamiento solicitadas al procesador y explique el razonamiento detrás de ella.
3. Mencione cuantos agrupamientos deben asociarse con las clases informacionales.
4. Mencione dos parámetros estadísticos que definen la distribución multivariada Gaussiana.
5. Explique por qué es necesario contar en este punto del análisis con descriptores estadísticos de las clases candidatas de entrenamiento.
6. Mencione una diferencia entre los métodos de selección de clases de entrenamiento supervisado y no-supervisado.
7. Describa una forma de "observar" las características espectrales de las clases candidatas de entrenamiento.
8. Identifique las regiones de la gráfica biespectral pertenecientes a los tres grandes grupos de tipos de cobertura.
9. Mencione cuatro razones del porqué clases de agrupamiento similares espectralmente son combinadas.
10. En la figura III-16, se muestran dos pares de funciones de distribución en una dimensión. ¿En que caso la distancia estadística entre las funciones de densidad es mayor?




Figura III-16. Dos pares de distribuciones en una dimensión.

11. Mencione dos características de la función de distribución Gaussiana que determinan la distancia estadística entre las funciones de densidad.
12. Cuál es la importancia de conocer la distancia estadística entre todos los posibles pares de clases?
13. Como se puede determinar el valor mínimo permitible de divergencia transformada?
14. Cuales son dos características deseables de las clases de entrenamiento finales?
15. De los métodos de unión y eliminación, cual es el mas adecuado?
16. Si encontramos valores de divergencia transformada menores a 1500 en las nuevas clases de entrenamiento, debemos repetir alguno de los pasos anteriores o podemos continuar el análisis?

CAPITULO IV. CLASIFICACION DEL AREA DE ESTUDIO

Al finalizar este capítulo, Usted sera capaz de:

1. Nombrar y describir brevemente la regla de decisión utilizada en el procesador CLASSIFYPOINTS.
2. Describir brevemente el algoritmo de clasificación ECHO.
3. Descibir el algoritmo de clasificación conocido como "distancia mínima".

Una vez que hemos creado un conjunto adecuado de clases de entrenamiento, podemos realizar uno de los pasos mas importante del proceso de análisis, la clasificación. Nosotros podemos tener disponible unicamente un algoritmo de clasificación o bien podremos seleccionar entre varios de ellos. Con el objeto de ejemplificar esta situación y realizar una comparacion, a continuación discutiremos tres diferentes algoritmos de clasificación - maxima verosimilitud, ECHO y distancia mínima.

Un algoritmo de clasificación debe ser definido en términos cuantitativos con el objeto de que el computador pueda trabajar con él. Esto puede lograrse definiendo un conjunto de funciones (expresiones matemáticas) que correspondan a las clases de entrenamiento. Estas funciones, las cuales son denominadas "funciones discriminantes", son construídas de tal manera que cuando los valores de los elementos que estan siendo clasificados, son substituidos en dicha función, la función con el valor resultante mas grande (o alternativamente, el resultado mas pequeño) será a la que dicho elemento será asignado en la clasificación.

El algoritmo de clasificación utilizado por el procesador CLASSIFYPOINTS en LARSYS se basa en la regla de clasificación conocida como máxima verosimilitud. Cada elemento a clasificar es "comparado" a cada una de las clases de entrenamiento y asignado a la clase a la que mas se parece. Las funciones discriminantes para el clasificador de máxima verosimilitud se derivan de la teoría de decisión estadística minimizando la probabilidad de cometer errores en la clasificación (ver la seccion 3.6 del libro de Swain y Davis para mas detalles). Cuando las clases están caracterizadas por funciones de distribución multivariadas normales, las funciones discriminantes son definidas en términos de los vectores de las medias y las matrices de covarianza de las clases. El conjunto de funciones discriminantes del clasificador de máxima verosimilitud se define de tal manera que los datos de los elementos son substituidos en cada una de las funciones, aquella que presente el valor mas alto determina la clase a la cual el elemento será asignado.

El procesador CLASSIFYPOINTS emplea únicamente información espectral al realizar las decisiones en la clasificación. El

algoritmo de clasificación utilizado por ECHO emplea información espacial y espectral. ECHO son las siglas de "Extraction and Classification of Homogenous Objects". Cuando procesamos un conjunto de datos, ECHO divide inicialmente la escena en celdas rectangulares. El tamaño de las celdas es determinado por el analista basándose en el tamaño promedio esperado de los objetos presentes en la imagen. La figura IV-1 muestra un conjunto de datos dividido en celdas de 3 por 3 elementos. El clasificador ECHO examina los elementos dentro de la celda y realiza una prueba para determinar si los elementos son o no estadísticamente similares. Si lo son, se decide que pertenecen al mismo objeto en la escena. El clasificador examina a continuación la siguiente celda. Si los elementos de esta celda son similares, la prueba se realiza en ambas celdas. Si las dos presentan propiedades estadísticas similares, se combinan para formar un objeto. El proceso continúa, anexando celdas a objetos, hasta que el clasificador encuentra una celda que no es estadísticamente similar a las celdas que le rodean. Esta celda pertenece entonces a un objeto diferente. Una vez que los objetos




Figura IV-1. Conjunto de datos dividido por ECHO en celdas de 3 por 3. Cada punto representa un elemento en la escena.

han sido identificados, todos los elementos de un objeto son clasificados como un grupo comparando la distribución de probabilidad estimada para esos elementos con la distribución de probabilidad de cada una de las clases de entrenamiento. De esta manera los elementos de un objeto son clasificados al mismo tiempo, como pertenecientes a la clase de entrenamiento a la que más se semejan. Si el clasificador encuentra una celda no homogénea (celdas

que fallan en la prueba estadística de homogeneidad), cada elemento de la celda es clasificado independientemente utilizando la regla de decisión de máxima verosimilitud (CLASSIFYPOINTS). El clasificador ECHO utiliza el mismo tipo de clases de entrenamiento que el procesador CLASSIFYPOINTS: el vector de las media y la matriz de covarianza de cada clase de entrenamiento.

El clasificador de distancia mínima es de tipo "puntual" como el del procesador CLASSIFYPOINTS, en el sentido de que cada elemento de la escena es clasificado independientemente. El algoritmo de clasificación de distancia mínima es muy simple tanto en su conceptualización como programación, en comparación con los clasificadores anteriores. Para cada elemento en la escena, se calcula una distancia multidimensional entre los valores de un elemento y el vector de las medias de cada una de las clases de entrenamiento. En este clasificador la medida de la distancia es utilizada como función discriminante. Los elementos son asignados entonces a la clase de entrenamiento mas cercana, esto es a la clase con el menor valor en la función discriminante. Este clasificador es mas eficiente en terminos del tiempo de máquina empleado, pero menos poderoso que el clasificador de máxima verosimilitud. Sin embargo, el clasificador de distancia mínima tiende a producir aproximadamente los mismos resultados que el clasificador de máxima verosimilitud, cuando las clases de entrenamiento son generadas de tal manera de que un gran número de clases de entrenamiento representen todas las características espectrales de la escena. El algoritmo de análisis de agrupamientos descrito anteriormente posee estas características. El algoritmo de maxima verosimilitud tiende a producir mejores resultados cuando las clases de interés son muy semejantes y presentan traslape en sus características espectrales.

Autoevaluacion

1. Describa brevemente el tipo de regla de decisión utilizada por el procesador CLASSIFYPOINTS.
2. Con la ayuda de la figura IV-1, describa cómo trabaja el clasificador ECHO.
3. Realice una comparación entre el clasificador de distancia mínima y el clasificador de máxima verosimilitud.

CAPITULO V. REPRESENTACION PICTORICA O TABULAR DE LOS RESULTADOS DE LA CLASIFICACION

Al finalizar este capítulo, Usted podrá:


1. Nombrar las dos formas en que podemos representar los resultados de una clasificación y explicar las razones de su uso.

Al finalizar la clasificación espectral, los resultados pueden desplegarse en diferentes formatos de acuerdo a las especificaciones y necesidades del usuario. Existen dos formas de realizar esto: en forma pictórica o en forma tabular. Por ejemplo, el área clasificada puede desplegarse en un mapa a la escala, proyección geográfica y unidad de mapeo deseada. Las clases de cobertura del terreno pueden representarse por (1) caracteres alfa-numéricos (figura V-1), (2) símbolos gráficos (figura V-2), (3) niveles de grises (figura V-3), (4) líneas entre las clases (figura V-4), o (5) diferentes colores. Los resultados de la clasificación pueden representarse también por mapas temáticos en los que se muestre únicamente una clase.


Otra forma de desplegar los resultados de la clasificación, es en forma tabular, esta puede utilizarse cuando únicamente se requiera la información sobre la superficie del terreno ocupada por cada uno de los tipos de cobertura en el área de estudio. En este caso se imprimirá una tabla indicando el número de elementos clasificados en cada una de las clases de cobertura de terreno. El área representada por cada punto se multiplica por el número de puntos del tipo de cobertura para obtener el área total de cada clase. Para datos Landsat corregidos geométricamente a escala 1:24,000 para coincidir con mapas del Servicio Geológico de los Estados Unidos, el factor de conversión es 0.46 hectáreas por elemento. Por lo tanto si encontramos que 19,465 elementos fueron clasificados como bosque caducifolio en una imagen Landsat, podemos calcular que el área de estudio cuenta con 9,019.4 hectáreas de este tipo de bosque.

Autoevaluación

1. Cual es la ventaja de desplegar los resultados de la clasificación en forma pictórica?
2. Cuando debemos emplear la forma tabular para imprimir los resultados de la clasificación.



Agua




Bosque-1



Pasto



Suelos




Arena




Chaparral

Figura V-2. Representación con símbolos gráficos de una clasificación multiespectral.



-Agua



-Arena




-Chaparral-2



-Suelos



-Pasto



-Bosque-2




-Bosque-1



-Chaparral-1

Figura V-3. Representación en tonos de gris de una clasificación multispectral.



A - Pastos

D - Agua

B - Bosque-1

E - Chaparral

C - Arena

F - Suelos

Figura V-4. Representación con líneas entre las clases de una clasificación multiespectral.

CAPITULO VI. EVALUACION DE LOS RESULTADOS DE LA CLASIFICACION

Al finalizar este capítulo, Usted podrá:

1. Utilizando como ejemplo una matriz de confusión de los resultados de la clasificación, indicar qué elementos han sido correctamente clasificados, cuales son los errores de omisión y de comisión para una determinada clase.

Para que una clasificación de datos multiespectrales pueda tener aplicación, nosotros debemos determinar su precisión y confiabilidad. Utilizando el método de análisis numérico, podemos conocer cuantitativamente el grado de precisión de una clasificación multiespectral. La experiencia muestra que el método conocido como "comportamiento de campos de prueba" es una forma adecuada para determinar la precisión de una clasificación. En este método se seleccionan campos de prueba de identidad conocida y el computador determina el porcentaje de elementos correctamente clasificados. Estos campos deben contener un solo tipo de cobertura del terreno. Puesto que la identidad de los elementos de cada campo de prueba es conocida, así como su posición en el conjunto de datos, el computador puede localizar estos elementos en los resultados de la clasificación (almacenados en una cinta magnética), observar la clase a la que cada elemento fue asignado, y comparar este resultado con la identidad de cada elemento (determinada con la información de campo) y de esta forma conocer si el elemento fue clasificado correctamente. Comúnmente, se seleccionan varios campos de prueba para evaluar la precisión de la clasificación de cada una de las clases informacionales. El computador examina y tabula la decisión tomada para cada elemento en cada campo de prueba e imprime un resumen por cada campo, o por cada clase de cobertura del terreno (todos los campos de prueba seleccionados para esa clase informacional), o ambos, según lo especificado por el analista. Un ejemplo de los resultados de la prueba de comportamiento del clasificador se muestra en la tabla VI-1. Esta tabla es denominada "matriz de confusión de los resultados de la clasificación.

¿Qué nos indican los números en la matriz de confusión, acerca de la clasificación? Miremos primero los 9,634 elementos del bosque de coníferas. La tabla indica que 9,110 de estos elementos, o el 94.6% se clasificaron correctamente. En la misma línea, la tabla indica que 22 elementos, que el analista sabe que pertenecen a la clase Coníferas, fueron clasificados incorrectamente como Bosque Caducifolio, 53 fueron mal clasificados como Pastizal, 21 como Suelo, y 428 fueron erróneamente asignados a la clase Agua. Esto se interpreta como 524 errores de omisión para los 9,634 elementos de la clase Bosque de Coníferas. Ahora, en la columna de las Coníferas, encontramos 187 errores de comisión para la clase Bosque de Coníferas. Esto es, 187 elementos fueron erróneamente asignados a la clase Coníferas.

	No. de Muestras	Porcentaje Correcto	Coníferas	Caduc.	Pastizal	Suelo	Agua
Coníferas	9,634	94.6	9,110	22	53	21	428
Caduc.	1,475	87.5	113	1,286	76	0	0
Pastizal	3,677	81.2	49	129	2,988	510	1
Suelo	35	97.1	0	0	1	34	0
Agua	1,349	98.9	15	0	0	0	1,334
Totales	16,170		9,287	1,437	3,118	565	1,763

Tabla VI-1. Matriz de confusión de los resultados de la clasificación.

Los cinco números en la diagonal principal de la matriz se pueden sumar y este total se divide entre el número total de elementos para obtener lo que denominamos el comportamiento general de la clasificación. Para la tabla VI-1, este valor es igual a $(9,110+1,286+2,988+34+1,334)/16,170 = 91.2\%$.

En ocasiones, los campos de prueba se seleccionan con base en lo que observamos en las imágenes en blanco y negro del conjunto de datos. Esta selección del centro de campos grandes y homogéneos como base para probar al clasificador produce un desvío al evaluar la precisión de la clasificación. Existe un método estadístico que prácticamente elimina este problema. Utilizando este método, primero dividimos el área de estudio en bloques de dos o tres elementos de lado, formando una red en los datos. A continuación, empleando un programa de números aleatorios, se seleccionan bloques. El número de bloques seleccionado corresponde a un determinado porcentaje (normalmente el 5%) del área de estudio. El tipo de cobertura de cada bloque seleccionado es identificado por medio de los datos de referencia; los bloques "mixtos" son eliminados. Los bloques de un mismo tipo de cobertura son unidos y empleados para evaluar la precisión de la clasificación de la misma forma que se hizo con los campos de prueba seleccionados en forma "supervisada". Si bien este método de selección de campos de prueba requiere de una mayor cantidad de datos de referencia y recursos humanos, es más adecuado para proporcionar un muestreo representativo que servirá como base para la evaluación de la clasificación.

Dos aspectos adicionales a considerar cuando estamos seleccionando los campos de prueba son que estos no deben coincidir con campos o áreas de entrenamiento y deben contener en total para cada clase la misma proporción en que ocurren los tipos de cobertura en la escena (esto se asegura con el método de muestreo al azar de bloques). Por ejemplo, consideremos una imagen que contenga el mismo número de elementos de bosque y agua. Supongamos que decidimos

emplear 100 elementos y escogemos 90 de la clase agua y 10 de la clase bosque, y encontramos que 80 elementos de agua están clasificados correctamente mientras que solo un elemento de bosque se clasificó correctamente. Podemos concluir que nuestra clasificación es 81% correcta? No - tenemos un estimador desviado de la precisión de la clasificación. Si hubieramos escogido 50 elementos de agua y 50 de bosque para realizar la prueba y tenemos la misma precisión para las clases bosque y agua, deberemos tener 45 elementos de agua y 5 elementos de bosque clasificados correctamente. La estimación no desviada de la precisión de la clasificación es de solo el 50%.

Autoevaluación

1. En la tabla VI-1, indique los elementos clasificados correctamente, los errores de omisión y de comisión para la clase Pastizal.

CAPITULO VII. CONSIDERACIONES FINALES

Usted ha finalizado paso por paso, un análisis numérico de un conjunto de datos del barredor multiespectral, desde la selección de los datos hasta la evaluación de los resultados de la clasificación. Hemos presentado los pasos del análisis en una forma lineal. Esta presentación se adoptó con el único propósito de facilitar la explicación - en el trabajo cotidiano, deberemos ejecutar algún o algunos pasos en varias ocasiones.

El procedimiento de análisis empleado en este caso de estudio esta basado en la experiencia de los investigadores de LARS. Sin embargo, es importante enafatizar que este taller es solo una introducción a los procedimientos de analisis y no "al" procedimiento único. El metodo de análisis usado en este taller fue desarrollado haciendo uso inteligente e imaginativo de los algoritmos de clasificación disponibles. Diferentes aplicaciones, quizá su aplicación, requiera de un metodo diferente.

Ahora tenemos resultados de una clasificación de nuestra área de estudio. Estos por sí mismos no son un producto real de interés. En realidad, el análisis se lleva a cabo para obtener información que será usada en trabajos tales como, manejo de bosques o planificación del uso del suelo. Por ejemplo, el objetivo del análisis puede ser el de encontrar donde se encuentran algunos tipos de cobertura o qué proporción del área de estudio está ocupada por un tipo de cobertura, con el objeto de que podamos tomar decisiones respecto a su manejo. Para completar el análisis, el objetivo inicial de este debe ser revisado para extraer la información requerida.

Ejemplos de resultados de análisis y la extracción de información útil a partir de clasificaciones de datos multiespectrales, pueden encontrarse en varias revistas, entre las cuales podemos mencionar las siguientes:

- Pattern Recognition
- Remote Sensing of Environment
- IEEE Transactions on Geosciences and Remote Sensing
- Journal of Soil and Water Conservation
- Photogrammetric Engineering and Remote Sensing
- Agronomy Journal

También es posible encontrar ejemplos en las publicaciones de LARS, memorias de simposia y conferencias, etc.