

PROBLEMÁTICA EN LA CLASIFICACIÓN DE IMÁGENES DE SATÉLITE LANDSAT

Jesús García-Consuegra Bleda

Jesús García-Consuegra Bleda es Profesor del Departamento de Informática en la Escuela Universitaria Politécnica de Albacete, y miembro de la Sección de Teledetección y GIS (Instituto de Desarrollo Regional) de la Universidad de Castilla-La Mancha.

RESUMEN

Este trabajo da una introducción a la clasificación de imágenes multispectrales de satélite, a la naturaleza de dichas imágenes, a la problemática que conlleva la clasificación de los elementos de información (pixel), así como algunas de las técnicas planteadas para su resolución.

1. PROCESO DE FORMACIÓN DE IMÁGENES

SATÉLITES como LANDSAT (Lee y Landgrebe, 1993), SPOT (Borry et al., 1993), etc., por medio de multisensores, miden la energía reflejada por la superficie terrestre a diferentes longitudes de onda. Cada longitud de onda y su entorno define una franja (o banda) de interés en el espectro de electromagnético. De esta forma se obtienen las denominadas imágenes multispectrales, donde cada imagen se forma a partir de los datos escaneados en una determinada banda.

El proceso de adquisición de información es sencillo (Curran, 1985), a medida que el satélite se desplaza describiendo una órbita al rededor de la Tierra (Fig. 1), sus sensores van escaneando la superficie de la misma. Cada unidad elemental de información medida (pixel) de la imagen se identifica con la energía media radiada por un área cuadrada de la superficie terrestre para cada banda. Dicha energía es codificada como un valor digital, lo que permite su visualización como una imagen en escala de grises. Se denomina resolución espacial a las dimensiones del área cuadrada representada por cada pixel.

Como todo proceso de medida, la información recogida en las imágenes de satélite no se haya exenta de errores. Los errores del proceso de captura son de naturaleza variada, pudiéndose agrupar en dos am-




FIGURA 1. Diagrama de un explorador de barrido.

plios grupos: radiométricos y geométricos. Los errores radiométricos, son aquellos que modifican el valor real de la energía captada por el sensor del satélite. Entre las causas de los errores radiométricos se encuentran aquellas debidas a la presencia de la atmósfera; a la orografía del terreno; a la propia geometría en la captura de información; a un mal funcionamiento del sensor; y, a fallos en la transmisión o recepción de las imágenes. Por otro lado, los errores geométricos modifican la geometría de la imagen. Siendo estos últimos debidos a la curvatura de la Tierra; a su propio movimiento giratorio; a variaciones en la posición del satélite; y distorsiones provocadas por el sensor.

2. NATURALEZA DE LOS ELEMENTOS A CLASIFICAR

En este artículo nos vamos a centrar en las imágenes multiespectrales del satélite Landsat de la serie V con sensor TM (Thematic Mapper) (Mather, 1987; y Curran, 1985) como elemento de apoyo a los conceptos que se exponen. Este sensor posee una resolución espectral de 7 bandas, con una resolución espacial de 30×30 m para las bandas 1-5 y 7 y de 120×120 m para la banda 6, con 256 niveles de cuantificación. Este sensor se encuadra dentro de los sensores de barrido bidireccional, donde en cada oscilación del espejo supone 16 líneas de ba-

rido. De esta forma se precisan 16 sensores por banda, salvo la banda térmica con sólo cuatro detectores ya que registra una menor resolución (120 m). En la tabla 1, se muestra la longitud de onda y el ancho de banda espectral ocupada por cada banda para este tipo de sensor, así como el campo de aplicación de la información medida por dicha banda. En la figura 2, se muestra el espectro electromagnético.

Otra forma de interpretar la información contenida en las imágenes consiste en considerar cada pixel como un vector de d -características (siendo d el número de bandas bajo estudio) donde cada característica se identifica con una coordenada. El espacio d -dimensional así definido lo denominaremos **espacio de características**. De este modo, se puede aplicar la teoría vectorial y las técnicas de análisis multiespectral (Cuadras, 1991).

Si se pudieran representar los pixeles que forman la imagen en un sistema de coordenadas d -dimensional, siempre bajo la hipótesis de un sistema de características ortogonales, se podría observar que pixeles representado clases distintas se encuentran distanciados. Por contra, pixeles de coberturas similares (tramos de carretera, parcelas con un mismo cultivo, etc.) estarían muy próximos, formando una nube de puntos más o menos compacta. Dicha nube es la representación visual de la clase. Una forma de representar la clase es mediante su centroide (media de todos los puntos pertenecientes a la clase), basándonos en una distribución hiperbólica de los puntos en la nube.

TABLA 1.
Principales aplicaciones de cada una de las bandas TM de LANDSAT.

BANDA	λ (μm)	APLICACIONES PRINCIPALES
1	0,45-0,52	Cartografía de aguas costeras. Diferenciación entre suelo y vegetación. Diferenciación entre vegetación y coníferas.
2	0,52-0,60	Medida de la reflectancia en la banda verde para el estado sanitario de la vegetación.
3	0,63-0,69	Diferenciación de especies vegetales gracias a la determinación de la absorción clorofílica.
4	0,76-0,90	Delimitación de masas de agua. Inventarios de la biomasa.
5	1,55-1,75	Diferenciación entre nubes y cubierta de nieve. Medida de la humedad de la vegetación. Medida de la humedad del suelo.
6	10,40-12,5	Termografías. Información sobre el desecamiento de la vegetación. Datos térmicos en formaciones geológicas (complementa la información de las otras bandas).
7	2,08-2,35	Discriminación de tipos de rocas (mineral y petróleo). Cartografía hidrométrica.

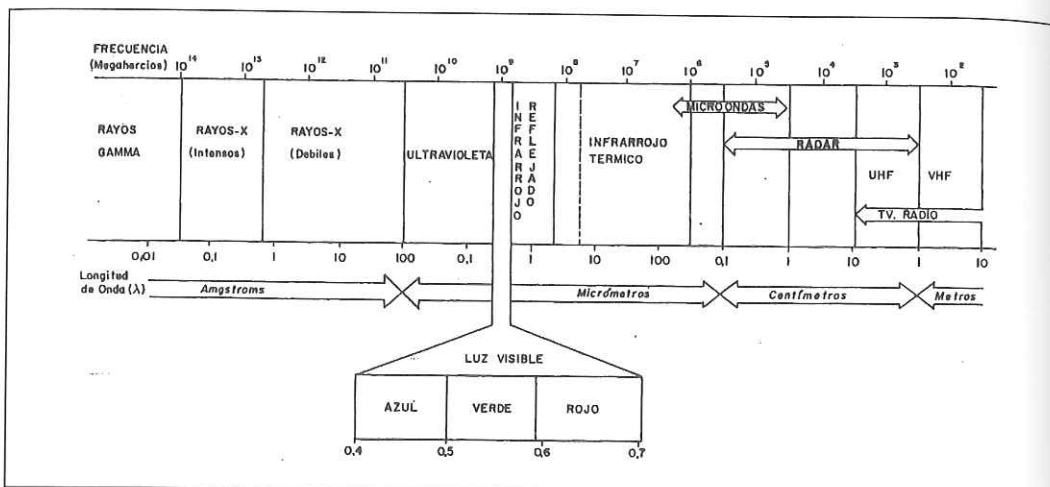


FIGURA 2. Espectro electromagnético.

Esta simple representación visual da una idea de las clases presentes en la imagen multispectral y de la discriminabilidad entre clases, es decir, del número de nubes identificables y de su separación, respectivamente. Lo que nos da una medida del futuro comportamiento del clasificador. De manera que, aquellas clases más distantes del resto serán fácilmente discriminadas. Por contra, aquellas clases más próximas dificultarán su clasificación, como se verá en el cuarto apartado. La figura siguiente muestra la reflectividad de algunas clases genéricas típicas a lo largo del espectro electromagnético lo que, junto a la tabla 1, permite identificar su comportamiento en cada banda.




FIGURA 3. Porcentaje de reflectividad de distintas coberturas en el espectro electromagnético.

3. PROCESO DE CLASIFICACIÓN

El objetivo principal de la clasificación de imágenes de satélite consiste en identificar las zonas (parcelas o regiones), y su localización, ocupadas por tipos (clases) de cubiertas dadas o deducidas de la superficie terrestre, por medio de métodos de reconocimiento de patrones (Mather, 1987; Chuvieco, 1996; y Curran, 1985).

Tradicionalmente, esta tarea se ha estado realizando mediante métodos estadísticos de clasificación. Básicamente, consisten en etiquetar (clasificar) cada pixel de la imagen multiespectral (Jain, 1989; y, Maravall, 1993) como perteneciente a una clase. El proceso en el que se etiquetan los pixeles, la forma de definir las clases y los criterios de comparación entre pixel y clase, nos van a permitir diferenciar entre los distintos métodos de clasificación. Así, dependiendo del origen de las clases los procesos se pueden agrupar en supervisados y no-supervisados o automáticos.

Clasificadores supervisados

La caracterización de cada clase o categoría de interés se determina a partir de una muestra *dada* de pixeles de la imagen. La identificación de dichos pixeles se basa en un conocimiento previo de la zona cubierta por la imagen o en un trabajo de recogida de información en campo. Con lo que se pretende que el clasificador tenga una perfecta identificación y caracterización de las clases de interés.

Clasificadores no-supervisados o automáticos

En este grupo, es el propio proceso de clasificación el que se encarga de determinar las clases espectrales identificables en la imagen, es decir, los métodos no-supervisados realizan una búsqueda automática de grupos de valores homogéneos dentro de la imagen. Dejando al analista encargado de establecer la relación entre las clases encontradas con las categorías de interés.

En el criterio de comparación influyen tanto la forma de caracterizar la clase como el propio criterio de semejanza o diferencia (distancia). Así, se puede establecer una nueva agrupación de los clasificadores en función de la forma de caracterizar las clases en: paramétricos y no-paramétricos. Ambos grupos se basan en la regla de decisión bayesiana (1),

$$P\left(\frac{\alpha_i}{X}\right) = \frac{P\left(\frac{X}{\alpha_i}\right) P(\alpha_i)}{P(X)} \quad (1)$$

donde $P\left(\frac{\alpha_i}{X}\right)$ es la probabilidad de que un pixel X pertenezca a la clase α_i . $P\left(\frac{X}{\alpha_i}\right)$ es la probabilidad de que dada α_i , el valor de la variable aleatoria sea X . $P(\alpha_i)$ es la probabilidad *a priori* de que se presente un elemento de la clase α_i . $P(X)$ es la probabilidad *a priori* de que se presente un objeto a clasificar con un vector de características igual a X . La diferencia entre los métodos paramétricos y no-paramétricos estriba en que en los primeros se considera conocida la función densidad de probabilidad de las clases –usualmente, gaussiana–, caracterizados por un número determinado de parámetros –en nuestro ejemplo, por la media y su desviación típica–, los cuales se pueden obtener, de forma aproximada, a partir de las muestras dadas (caso de métodos supervisados) o de forma progresiva e iterativa (caso de métodos no-supervisados). Por contra, en los métodos no-paramétricos se ignora las funciones densidad de probabilidad que caracterizan las clases, siendo necesario un paso previo para la estimación de las funciones de probabilidad a partir de las muestras.

Criterios de semejanza y diferencia hay muchos, unos miden la diferencia o semejanza de un pixel con el elemento característico de cada clase (centroide) sin deformar el espacio de características (caso distancia euclídea), otros tratan de corregir las deformaciones introducidas por la no-ortogonalidad de las características medidas (caso distancia Mahalanobish) y por último están aquellos criterios que calculan la distancia tras aplicar una expansión logarítmica al espacio de características (distancia de Jeffries-Matusita).

Por último, restaría presentar las diferencias metodológicas introducidas por los distintos métodos para llevar a cabo la clasificación. Dado que cada método tiene entidad propia y diferenciable del resto sería necesario una exposición larga e injustificada en este trabajo de todos los métodos.

4. PROBLEMÁTICA DE LA CLASIFICACIÓN

De lo visto hasta ahora, se puede tener la sensación de que el caso ideal para la clasificación de los píxeles es aquel en el que las nubes de puntos se encuentran lo suficientemente alejadas para evitar que existan píxeles de una clase más próximos o dentro de otra clase. Este caso ideal suele ser el más difícil de encontrar en las imágenes de satélite y los motivos son múltiples. De una parte nos encontramos que la resolución espacial del sensor TM, en su caso más favorable, es de 30×30 m lo que supone una superficie con amplitud suficiente para que en muchos casos no represente una cobertura homogénea (límites

de las parcelas, carreteras, cultivos leñosos como vid, almendro, etc.). Esto supone una gran cantidad de píxeles cuya representación en el espacio de características se encontrará en medio de las clases que lo forman (si es que éstas se encontrasen en suficiente cantidad en forma de píxeles puros). Dichos píxeles son denominados píxeles mixtos o de borde, por la cobertura que estos representan. En contraposición a los píxeles mixtos se encuentran los píxeles puros, aquellos que si representan una cobertura homogénea.

Los píxeles mixtos son casi siempre una fuente de error a la hora de clasificar. Cuando nos encontramos con una presencia suficientemente significativa de píxeles mixtos pueden modificar sensiblemente el cálculo del centroide característico de las clases que lo forman, e incluso llegar a formar su propia clase. Esto es debido a que el cálculo del centroide es bastante sensible a la distribución de los píxeles en el espacio de características, es decir, una presencia importante de muestras muy próximas entre sí, atraerá el centroide. Por contra, concentraciones pequeñas de píxeles no serán significativas en el cálculo del centroide, estos píxeles mixtos se encontrarán dispersos en el espacio d-dimensional provocando, casi siempre, errores al ser clasificados como perteneciente a aquella nube a la que se encuentra más próximo.

Otro factor importante es la dispersión que una misma cobertura nos va a ofrecer en función de elementos imponderables (Chuvieco, 1996) como (ver fig. 4):

- (1) Ángulo de iluminación solar, muy dependiente de la fecha del año y del momento de paso del satélite y ángulo de observación, relacionado con la órbita del satélite y con las características del sensor.
- (2 y 3) Modificaciones que el relieve introduce en el ángulo de iluminación (pendiente u orientación de las laderas).
- (4) Influencia de la atmósfera, especialmente en lo que se refiere a la dispersión selectiva en distintas longitudes de onda.
- (5 y 6) Variaciones medio ambientales en la cubierta: asociación con otras superficies, homogeneidad que presenta, estado fenológico, etc.

Estos elementos se ven acentuados en una imagen completa del satélite Landsat (210×173 km), por la gran separación que puede existir entre parcelas con cultivos similares, acentuando, con ello, las diferencias en las condiciones de adquisición de los píxeles. Estas variaciones provocan que la nube formada tenga una forma compleja, lo que dificulta la determinación de su densidad de probabilidad (métodos no-paramétricos), alejándola de las densidades típicas (métodos paramétricos), sobre todo de la distribución gaussiana ampliamente deseada. La manera que hasta la fecha sea recurrido para resolver este problema ha sido la determinación de zonas de respuesta espectral homogénea para




FIGURA 4. Factores causantes de la diversidad de la firma espectral de un mismo cultivo.

cada clase o cobertura. La problemática que encierra este proceso es casi mayor que el problema que trata de resolver. Los motivos fundamentales son la precariedad del límite de cada zona. El establecimiento de un límite supone que parcelas vecinas, con una misma cobertura, a ambos lados del límite de una zona tienen una respuesta espectral distinta entre sí, y similar a otras parcelas mucho más distantes sometidas a otras condiciones de adquisición. A esto hay que añadir, la temporalidad de la zona homogénea, ya que únicamente vale para la fecha en la que se obtuvo, no pudiéndose extrapolar a otras fechas sin incurrir en graves errores. En el mejor de los casos, este estudio debe repetirse para cada clase lo que supone un esfuerzo en trabajo de campo superior al ahorro que las técnicas de teledetección introducen. En la práctica, éstas zonas se delimitan a grandes rasgos bajo conceptos genéricos (por ejemplo, la altitud) que no incurran en grandes costes ni esfuerzos.

En los clasificadores estadísticos, supervisado y no-supervisado, no se explota la información espacial, es decir, la relación de vecindad en-

tre los píxeles. Lo que provoca que píxeles vecinos, pertenecientes a la misma parcela, no sean asignados a la misma clase con demasiada frecuencia. Llegando a formar pequeñas regiones o píxeles aislados, en algunos casos, lo que no solo significa un error en el proceso de clasificación sino que además es visualmente llamativo. Otro grave problema se plantea a la hora de clasificar regiones con una determinada textura (ver figura 5). Aquí los píxeles no se deben clasificar como oscuros o claros como harían los clasificadores estadísticos, es necesario recurrir a sistemas de segmentación de imágenes de texturas como: watershed (basado en la morfología matemática), wavelets (basado en las relaciones de frecuencia), bancos de filtros, sistemas piramidales, etc.




FIGURA 5. Imagen de tres zonas con textura, semejante a la que se obtendría en una fotografía aérea para cultivos como la vid, olivo, etc.

Pequeñas variaciones en los parámetros del clasificador pueden suponer que algunos píxeles, distribuidos aleatoriamente por la imagen, sean clasificados de forma diferente. Esto es más usual en píxeles de borde o mixtos, donde su semejanza con los centroides de las clases no es tan afín. Los analistas, al encontrar píxeles mal clasificados, suelen variar los parámetros del clasificador en un intento por corregirlo, provocando a su vez que otros píxeles sean reclasificados, es decir, regeneran el problema inicial en otro conjunto de píxeles.

Los clasificadores supervisados se basan en un conocimiento previo, del número y la naturaleza estadística espectral de las clases de interés, obtenido a partir de las muestras de entrenamiento. Por lo que, dichos clasificadores dependen fuertemente de la selección de dichas muestras. Este problema se ve incrementado por variaciones en la respuesta espectral de las clases fundamentado en, las anteriormente mencionadas, condiciones de adquisición de la imagen, en los diferentes estados fenológicos y en las variedades de los cultivos. Lo que conlleva una mayor dispersión de la nube. Por lo que una cantidad suficiente

de píxeles de entrenamiento pertenecientes a una misma clase pero con diferente respuesta espectral puede desplazar al centroide representativo de la clase, facilitando la clasificación errónea de algunos píxeles. Este problema está siendo resuelto mediante un proceso repetitivo de clasificación, donde en iteraciones sucesivas se clasifican aquellos píxeles previamente no clasificados que demuestren mayor afinidad con los píxeles de entrenamiento sugeridos en cada nueva iteración.

Por último, los clasificadores no-supervisados dependen fuertemente de la distribución de los píxeles en el espacio de características. Las principales críticas a estos clasificadores han sido el número y la naturaleza de clases obtenidas, es decir, el número de clases extraídas puede ser superior o inferior al deseado, junto a la necesidad de un paso posterior para la correlación entre las clases obtenidas con las deseadas. Tal y como ocurría en los clasificadores supervisados también aquí se va a modificar los parámetros para adaptar los resultados a aquellos deseados, con la consiguiente pérdida de exactitud en la clasificación.

5. CONCLUSIONES

El objetivo que se pretende alcanzar aquí es resaltar la complejidad que puede entrañar la caracterización de un tipo de cubierta a partir de sensores remotos. Como se ha expuesto, las distintas cubiertas de la superficie terrestre no tienen un comportamiento espectral único y permanente, que coincida con sus curvas de reflectividad espectral y permita reconocerlas sin confusión frente a otras superficies, motivado por las condiciones de adquisición y por el propio sistema.

De lo visto, se puede concluir que para realizar una correcta clasificación es necesario una buena compactación y discriminación de la nube de la clase, además de una separación entre nubes lo suficientemente grande como para no poseer umbrales de confusión. A este fin, se han orientado gran parte de los esfuerzos en investigación desarrollando nuevos criterios de semejanza y diferencia, algoritmos para la determinación de la función densidad de probabilidad, transformaciones que permitan reordenar las nubes de una forma más apropiada aislando (declustering) o resaltando (índices de vegetación, tasseled-cap,...) una determinada clase, ortogonalizando y reduciendo el número de bandas (componentes principales, técnicas de extracción y selección de características,...), incorporando sistemas más complejos para la clasificación (redes neuronales, sistemas expertos,...) en los que se consideren las regiones con textura (wavelets, watershed...), etc.

Además, se han desarrollado nuevos métodos de clasificación que contemplen la problemática planteada por los píxeles mixtos, mitigando el error global que supone al considerar los píxeles mixtos como

elementos de su clase predominante en el espacio de características. Para parcelas grandes (con una superficie muy superior a la resolución espacial del sensor) este problema puede suponer una mínima parte del error cometido, siendo por contra un elemento muy sensible para aquellas parcelas con una superficie pequeña o próxima a la resolución espacial del sensor.

En definitiva y a pesar de los problemas planteados en este trabajo, los estudios de la superficie terrestre basados en técnicas de teledetección han obtenido una alta precisión, siendo en muchos casos la única tecnología aplicable cuando el lugar bajo estudio no es de fácil acceso (áreas montañosas o, más recientemente, los estudios facilitados por las misiones espaciales a otros planetas del sistema solar).

Para concluir, se puede afirmar que los avances tecnológicos en materia de sensores con capacidad para aumentar la resolución espacial y espectral, junto con computadores cada vez más potentes hace pensar que el futuro de la teledetección está asegurado, y que en ese futuro muchos de los problemas aquí planteados dejarán de serlo, apareciendo otros de naturaleza distinta.

REFERENCIAS

- F. C. BORRY et al.: «*Evaluation of SPOT and TM data for forest stratification: A case study on small-size poplar stands*», IEEE Trans. Geoscience and Remote Sensing, vol. 31, 1993, pp. 483-490.
- CHUVIECO, E. 1996: *Fundamentos de Teledetección Espacial*. Madrid. RIALP S.A.
- CUADRAS, C.M. 1991: *Métodos de Análisis Multivariante*. Barcelona. PPU.
- CURRAN, P. J. 1985: *Principles of remote sensing*. New York. Longman Scientific & Technical.
- JAIN, A. K. 1989: *Fundamentals of Digital Image Processing*. U.S.A. Prentice-Hall.
- C. LEE and D. A. LANDGREBE: «*Analyzing high-dimensional multispectral data*», IEEE Trans. Geoscience and Remote Sensing, vol. 31, 1993, pp. 792-800.
- MARAVALL, D. 1993: *Reconocimiento de formas y visión artificial*. Ra-ma. Madrid.
- MATHER, P. M. 1987: *Computer Processing on Remotely Sensed Images*. Chichester. John Wiley.