

ALTERNATIVAS A LA DETERMINACIÓN DE LAS ZONAS ESPECTRALES HOMOGÉNEAS

Jesús García-Consuegra(*), Guillermo Cisneros(**) y Elena Navarro(*).

jdgarcia@info-ab.uclm.es

(*)Sección de Teledetección y SIG (IDR). Dpto. Informática(EPISA).

Universidad de Castilla-La Mancha. Campus Universitario s/n. 02071. Albacete.

(**)Grupo de Tratamiento de Imágenes. Universidad Politécnica de Madrid.

ETS. Ing. Telecomunicación. Ciudad Universitaria. 28040. Madrid.

Resumen

El proceso de clasificación constituye una de las actividades más críticas de la Teledetección. Los resultados obtenidos dependen de diferentes elementos (clases de información definidas, las imágenes elegidas, condiciones de adquisición de las imágenes, resolución espacial y espectral, etc.), y, sobre todo, de la forma en la que los clasificadores son entrenados. Para áreas suficientemente extensas, la complejidad de la imagen se ve incrementada. En este trabajo, nuestro interés se centra en la identificación del patrón espacial del cultivo de maíz en el acuífero 18 de la Mancha Oriental, así como en las consecuencias de esta caracterización en los clasificadores, en contraposición de las zonas espectrales homogéneas.

Abstract

One of the most critical activities of remote sensing consists of the classification process. The results yielded depend on several elements (information classes, remote sensed images, conditions of image acquisition, the spectral and spatial resolution, etc.) and, above all, on the way the classification algorithms are trained. The image complexity increases for sufficiently large areas. In this work, our interest is focused on the identification of the corn crop spatial pattern in the 18th aquifer of the Mancha Oriental, as well as the consequences of this characterization in the classification algorithm, as opposed to the Spectral Homogeneous Zones.

Palabras clave: Objeto homogéneo, respuesta espectral, clasificación, Landsat.

INTRODUCCIÓN

Los resultados obtenidos en el proceso de clasificación de imágenes de Teledetección dependen de un gran número de factores (clases de información definidas, las imágenes elegidas, condiciones de adquisición de las imágenes, resolución espacial y espectral, etc.), y, sobre todo, de la forma en la que los clasificadores son entrenados (Mather 1987). Tradicionalmente, las técnicas de entrenamiento se han agrupado en supervisadas, no supervisadas (clustering) y mixtas, pero todas ellas tratan de establecer las características espectrales representativas de cada clase (patrón o rango-región multispectral de validez). En el entrenamiento supervisado, el analista indica al clasificador la localización (píxeles en la imagen) de las áreas de entrenamiento (training fields) que mejor caracterizan la variabilidad de los distintos tipos de cubiertas. Por el contrario, el método no supervisado extrae las características, y algunas veces también el número de clases, de la distribución de los píxeles en el espacio de características. Las técnicas mixtas o híbridas combinan diferentes aspectos de los métodos supervisados y no supervisados en un intento por evitar sus debilidades.

Para áreas suficientemente extensas, también se debe considerar la variabilidad espacial de las características. Tradicionalmente, la variabilidad espacial se introduce mediante la subdivisión del área bajo estudio en función de criterios como las condiciones bio-climáticas, la elevación del terreno, las regiones naturales, tipo de suelo, etc. (Townshend 1987, Pastor y Broschart 1990, Carbone 1996). La principal deficiencia de este método es la determinación de los límites de validez espacial de cada sub-área, es decir, la localización de los límites de esas áreas de respuesta espectral homogénea (AREH). El problema que surge es por qué dos parcelas espacialmente próximas, pertenecientes a la misma clase de información, en diferentes AREH, tienen patrones característicos diferentes mientras que dos parcelas mucho más distantes, en la misma AREH, tienen el mismo patrón.

Dos son los objetivos de este trabajo. Por un lado, se exponen las limitaciones y/o deficiencias de las AREH a la hora de caracterizar la variabilidad espacial de las clases. Por otro lado, se presenta una metodología supervisada alternativa que permite establecer el patrón espacial de las clases, en una

etapa previa al proceso de clasificación. No es objetivo de este trabajo diseñar la muestra de entrenamiento, es decir, queda fuera de nuestro campo abordar problemas como la determinación del tamaño de la muestra, el procedimiento de selección de las muestras, la estimación de las medias y desviaciones, o límites espectrales de validez.

ÁREA DE ESTUDIO

Para validar nuestra propuesta se ha intentado establecer el patrón espacial del maíz, en el acuífero 18 de la Mancha Oriental, si éste existe. El acuífero se encuentra a caballo de las provincias de Albacete y Cuenca (Figura 1). Se extiende aproximadamente 120 km en dirección este-oeste, y 118 km en dirección norte-sur. Este acuífero es mayoritariamente rural, viéndose especialmente afectado por los años secos. La elección del cultivo de maíz se debe fundamentalmente por lo ampliamente cultivado en este acuífero y por tratarse de un cultivo de verano de regadío. Lo cual facilitará nuestro estudio tanto por su distribución espacial a lo largo del acuífero, como por la facilidad para su discriminación.



Figura 1. El acuífero 18 se encuentra a caballo de las provincias de Albacete y Cuenca.

METODOLOGÍA

Debido a las dimensiones y orografía del acuífero, se hace lógico pensar en la existencia de una alta

probabilidad de tener una gran variabilidad en las condiciones de adquisición en la imagen. De ahí, que la consideración de un único patrón (en adelante *patrón global*) para la caracterización de todas las clases sea difícil de asumir. Técnicas mixtas de entrenamiento no supondrán una solución al problema ya que, la dispersión, en el espacio de características, de las clases de información provocará la aparición de clases espectrales representando varias clases de información. Esto se traduce en un incremento de los niveles de confusión.

La determinación de AREH supone la mejor alternativa. Sin embargo, esta opción fue descartada debido a la dificultad implícita en la determinación del número de AREH en las que se debería dividir el acuífero, así como en la localización de los límites de validez de las AREH. Un intento por dar una respuesta a estos problemas exigía un trabajo de campo tan exhaustivo que haría innecesario un proceso de clasificación posterior.

Finalmente, para evitar los problemas antes mencionados, se optó por un patrón espacialmente continuo (en adelante *patrón continuo*) para toda el área bajo estudio. Las principales características son la carencia de límites de validez; y que se encuentra en consonancia con el enfoque Markoviano. Según el cual, la naturaleza varía de forma continua y no a saltos. Para evitar las variaciones locales en una misma parcela, el patrón continuo se obtiene a partir de los objetos homogéneos, es decir, de la parcela.

Las ventajas de considerar objetos homogéneos como elemento a clasificar frente al pixel son ampliamente conocidas en la comunidad científica. Por ello, como paso previo se extraen los objetos homogéneos (regiones en el área de Visión) siguiendo la metodología ECHO (Extraction and Classification of Homogeneous Objects). En nuestro caso, para cada objeto homogéneo se definieron los siguientes atributos: tamaño, medido como el número de píxeles que los forma; media y desviación típica para cada banda del espacio de características definido, como medio para definir su patrón característico; y su localización en coordenadas UTM, medido como su centroide espacial.

Una vez obtenidos los objetos homogéneos, el patrón continuo se obtiene a partir de la interpolación de los centroides de aquellas parcelas identificadas como maíz, de forma supervisada. El trabajo de campo permitió identificar una muestra bien distribuida de 149 objetos homogéneos de un número muy superior de parcelas. La muestra se

dividió en dos grupos: entrenamiento y test. El primer grupo se usó para definir el patrón continuo. Para lo cual se utilizó el método de kriging (Burrough 1986 y Cressie 1993). Éste interpolador proporciona además una medida de la incertidumbre debida al propio proceso de interpolación.

En la medición de la similitud de las muestras de test con el patrón interpolado, los métodos paramétricos fueron descartados por la forma en la cual el patrón continuo se obtuvo. No existe una función densidad de probabilidad de la clase maíz que varíe espacialmente, sino un centroide estimado. De ahí que sea preciso usar criterios de similitud y diferencia no-paramétricos, en un proceso de decisión de Máxima Similitud (Mínima Diferencia), cuando se está considerando con varias clases. En este trabajo, para validar nuestra propuesta, se ha considerado el criterio Vector Degree of Match (VDM) (Baraldi y Parmiggiani 1995) para comparar el centroide de cada muestra de test con los valores estimados por el patrón continuo, en las coordenadas del centroide de cada muestra.

RESULTADOS

La imagen de Teledetección usada en este trabajo es una imagen adquirida, en agosto de 1997, por el sensor Thematic Mapper a bordo del satélite Landsat V. En las tablas 1 y 2 se muestran los estadísticos de primer orden de las bandas originales, así como las características de los patrones continuo y global obtenidos a partir de la muestra de entrenamiento. La Tabla 3 muestra el error cuadrático medio entre el valor del centroide de la parcela de test y ambos patrones, para cada banda.

Band	Media	Desviación Standard	Rango Valores	
			Máximo	Mínimo
3	72.92	25.703	255	16
4	91.61	18.743	255	1
5	156.1	46.003	255	2

Tabla 1. Características de las bandas 3, 4 y 5

Band	Patrón Global Centroide	Patrón interpolado	
		Valor Max/Min	Rango
3	24.14	29/21	8
4	105.53	86/126	40
5	61.734	55/79	24

Tabla 2. Caracterización de los patrones continuo y global.

Banda	Patrón Global	Patrón Continuo
-------	---------------	-----------------

3	0.724	0.968
4	2.376	1.82
5	2.083	2.83

Tabla 3. Error cuadrático medio

En las Fig 2a y b, se muestran las iso-líneas obtenidas para el patrón continuo.




Figura 2: Iso-líneas del patrón continuo en las bandas 4 y 5.

CONCLUSIONES

Tanto la variabilidad espacial de los patrones de las clases, como las ventajas de la sustitución de los píxeles por objetos homogéneos son ampliamente conocidos en la comunidad científica. Como primera conclusión se puede decir que el cultivo maíz en el acuífero 18 presentó una variación espacial en su patrón. Los resultados obtenidos mostraron un error cuadrático medio similar para ambos patrones si bien, en general, parcela a parcela, el patrón continuo tuvo un mejor comportamiento. Varias parcelas presentaron una gran diferencia con el patrón continuo elevando los niveles de error. Las

diferencias de esas parcelas se debieron a condiciones de adquisición especiales.

Como se esperaba, el patrón continuo obtuvo la mejor caracterización de la variabilidad espacial del maíz. Este resultado se sustenta en parte debido a que el patrón global es un caso particular del continuo, cuando no existe ninguna variación espacial. Las bandas muestran un patrón diferente (Figura 2). Esto se corrobora por la propia naturaleza del proceso de captura. Así, las variaciones en las condiciones de captación no afectan por igual en todo el rango del espectro electromagnético. Por lo que el establecer las mismas zonas de respuesta espectral homogéneas es un proceso erróneo.

El uso de los objetos homogéneos implica diferentes ventajas: se recoge la variabilidad local en una única entidad; supone un ahorro computacional a la hora de aplicar la interpolación; y, el uso del centroide tiene una mayor justificación, ya que la nube formada por sus píxeles se asemejará a una distribución gaussiana por la forma en la que son obtenidos.

Esta metodología posee cuatro importantes ventajas:

1. No existe la necesidad de un conocimiento previo de la función densidad de probabilidad de las clases. Por otro lado, es muy difícil definir una función densidad de probabilidad dependiente de las coordenadas espaciales.
2. Los objetos homogéneos de entrenamiento pueden determinarse de forma supervisada, como se ha realizado en este trabajo, o de forma no supervisada.
3. El proceso de clasificación de los objetos homogéneos se realiza siguiendo el criterio de decisión de Máxima Similitud (Mínima Diferencia), usando el criterio de similitud no-paramétrico VDM.
4. El proceso de interpolación realizado para la definición del patrón continuo, asume el punto de vista markoviano de la variación continua de la naturaleza.

Además, esta metodología puede fácilmente aplicarse a otros cultivos. Por otro lado, desaparece la necesidad de establecer límites de validez de las zonas de respuesta espectral homogénea.

Sin embargo, se mantiene el problema de la selección de la muestra. El número de parcelas de entrenamiento y la localización de las mismas cobra mayor relevancia, si cabe, con esta propuesta alternativa.

REFERENCIAS

Baraldi A. and Parmiggiani F., "A neural network for unsupervised categorization of multivalued input patterns: an application to satellite image clustering", *IEEE Trans. Geoscience and Remote Sensing*, vol. 33, No 2, 1995, pp. 305-316.

Burrough, P.A., *Principles of Geographical Information Systems for Land Resources Assessment*, Oxford, Clarendon Press, 1986.

Carbone, G.J. et al., "Application of Remote Sensing and GIS Technologies with Physiological Crop Models", *Photogrammetric Engineering and Remote Sensing*, vol. 62, no. 2, 1996, pp. 171-179.

Cressie, N.A.C., *Statistics for Spatial Data*, John Wiley & Sons, 1993.

Mather P.M., *Computer Processing of Remotely-Sensed Images*, Edit. John Wiley & Sons, 1987.

Pastor, J. and Broschart M., "The spatial pattern of a northern conifer-hardwood landscape", *Landscape Ecology*, vol. 4, no. 1, 1990, pp. 55-68.

Townshend, J.R.G. et al., "Characterization and classification of South American land cover types using satellite data", *Int. J. Remote Sensing*, vol. 8, no. 8, 1987, 1189-1207.