Integration of multiple feature extraction and object oriented classification of aerial images for map updating

Recio, J.A.; Ruiz, L.A.; Fdez. Sarría, A.; Hermosilla, T. Dpto. Ingeniería Cartográfica, Geodesia y Fotogrametría Universidad Politécnica de Valencia Camino de Vera s/nº 46022 Valencia irecio@cgf.upv.es

Abstract

Update land use cartography plays an important role in GIS data maintenance. There are numerous suitable methods for the revision of these data, based on traditional photogrammetry or image analysis of aerial images. In this work, we analyse the object oriented classification combined with the description of spatial hierarchies between the objects in diverse scales.

The process begins with the segmentation of aerial images according to the plot borders drawn in the cadastral cartography. The groups of pixels belonging to the same plot are called objects and are treated as individual entities. Then, some descriptive features of each object are computed. These features are: spectral features (mean and standard deviation of the grey levels), textural features extracted from the grey level co-occurrence matrix, structural features describing the regular spatial patterns typical of some land uses, etc. Sub-objects extraction is based on local maximum filtering inside the object. Depending on the type of the objects to extract, crop types in our case, different features can be employed to describe the objects.

Objects are classified with decision trees generated with the C5 algorithm and its option *boosting*. This algorithm uses the inductive learning. Providing C5 with several samples, objects with their features and classes, C5 divides with exclusive rules the original set in some subsets as homogeneous as possible. The option *boosting* generates several decision trees based on the same training data, getting better accuracies. For each object, the predicted class is obtained as well as the confidence level with which the algorithm makes its prediction. This methodology allows to integrate numerous features and the information contained in the previous cartography. The results show a high accuracy in classifications of plots. This method shows to be encouraging to automatize the updating of thematic cartography with information extracted from aerial images.

Keywords: object oriented classification, feature extraction, aerial imagery, cartography update.

1.- INTRODUCCIÓN

Los Sistemas de Información Geográfica (SIG) se han convertido en una herramienta fundamental para la gestión del territorio. En los SIG con un enfoque agrario o catastral, la unidad mínima de información es un polígono, denominado con terminología variable: tesela, recinto, subparcela, con características homogéneas respecto a la leyenda definida.

La actualización de estas bases de datos se realiza mediante fotointerpretación sobre ortoimágenes, bien sobre las imágenes en papel, o directamente en pantalla. Los métodos de clasificación supervisada no se utilizan habitualmente en la asignación de clases a los polígonos.

En este trabajo se ha ensayado una metodología de clasificación supervisada de parcelas agrícolas, analizando las características de cada parcela en una imagen aérea.

2.- MATERIAL Y ZONA DE ESTUDIO

Los datos empleados para realizar este estudio se centran en los polígonos catastrales 1 a 9 y 17 a 19 del término municipal de Benicarló, en la provincia de Castellón. Se trata de un municipio eminentemente agrícola, donde los cultivos principales son cítricos, algarrobos, olivos y hortalizas.

A continuación se describen las características principales de los datos utilizados: las imágenes y las capas vectoriales de delimitación de parcelas.

a) <u>Imágenes</u>: Se parte de ortofotos aéreas digitales independientes que cubren la totalidad del término municipal de Benicarló. Fueron adquiridas en agosto de 2005, utilizando un sistema de cámaras fotogramétricas DMC (*Digital Mapping Camera*), cuyas características técnicas se muestran en la tabla 1.

Tabla 1.- Características técnicas básicas del sistema de cámaras aéreas digitales DMC.

Tipo de sensor	CCD (Charged-Coupled- Device) matricial			
Sensibilidad espectral	Azul: 400-580 μm Verde: 500-650 μm Rojo: 590-675 μm Infrarrojo: 675-850 μm Banda pancromática			
Resolución radiométrica	12 bits/píxel			
Resolución espacial	Detectores de 12 x 12 μm Imagen final: 0.5m/pixel			

b) <u>Ficheros vectoriales</u>: Polígonos y parcelas catastrales en formato vectorial *shape*. La figura 1 muestra el parcelario superpuesto sobre un detalle de la ortofoto CIR (Colour Infrared).



Figura 1.- Parcelario superpuesto sobre imagen CIR

Por otra parte, la programación específica de los métodos de procesado se ha realizado en el lenguaje de programación *IDL* y las operaciones básicas de visualización y preprocesado se han llevado a cabo con el programa de tratamiento de imágenes *ENVI*.

3.- METODOLOGÍA

3.1.- CLASIFICACIÓN ORIENTADA A OBJETOS

La utilización de imágenes de alta resolución para la identificación de usos o cultivos en parcelas agrícolas, presenta la dificultad del incremento en la variabilidad interna de las parcelas captadas. Esta variabilidad interna puede llevar a reducir la precisión de las clasificaciones basadas en datos espectrales utilizando el enfoque por píxel.

En la clasificación por píxel, se analiza el nivel digital del píxel en varias bandas espectrales, sin considerar las características del contexto en el que se encuentra. Se centra la atención en el análisis estadístico de los valores almacenados en los píxeles, más que en descubrir y entender los patrones espaciales que ellos siguen. Esta metodología da buenos resultados en las cubiertas espectralmente homogéneas, pero proporciona resultados menos satisfactorios en las cubiertas heterogéneas. Su principal inconveniente es que no tiene en cuenta la información espacial de la imagen (Blashcke et al., 2004).

Entre los rasgos más importantes para la interpretación visual humana siempre se incluyen las características espaciales de la imagen como son la textura, la forma, el tamaño, la presencia de sombras, la localización, etc. Para mejorar la interpretación automática de la imagen es necesario acercarse al entendimiento intuitivo humano de la imagen.

En los últimos años, los algoritmos clásicos de clasificación de imágenes basados en píxeles están siendo cada vez menos utilizados en el procesado de imágenes de alta resolución, en las cuales los píxeles vecinos están muy correlacionados y en muchos casos pertenecen a la misma clase informacional (Antunes et al., 2003).

Entre los métodos clasificadores que consideran la distribución espacial existente en la imagen hay que incluir los clasificadores orientados a objetos. En esta metodología se considera la forma, la textura y las propiedades espectrales de los objetos que forman la imagen, así como las relaciones existentes con los objetos vecinos situados en un contexto espacial más o menos cercano, aumentando de forma considerable las características descriptivas de los objetos que facilitarán su correcta clasificación. Siendo los objetos los que se clasifican y no los píxeles individualmente. La clasificación basada en objetos tiene su punto inicial y fundamental en la creación de objetos, definidos como agrupaciones de píxeles contiguos con características similares a los elementos del mundo real que modelan.

En este trabajo, se ha segmentado la imagen según los límites existentes en la cartografía catastral correspondientes a recintos o parcelas con un uso o cultivo homogéneo. De esta forma, se consigue generar objetos en la imagen con un mayor significado geográfico que el que tienen los píxeles, que realizan una división del espacio determinada por las características del sensor utilizado en lugar de por las características del territorio representado.

Para reducir el efecto de los posibles desajustes geométricos zonales entre ambas fuentes de datos (imágenes y parcelario vectorial) se ha realizado una erosión de dos píxeles a cada parcela, de forma que los valores de las zonas periféricas de cada una de ellas no se tengan en cuenta para la extracción de variables, reduciendo el riesgo de emplear datos correspondientes a píxeles de parcelas contiguas.

La clasificación de imágenes por parcelas es especialmente adecuada para la actualización de bases de datos de SIG de zonas agrícolas porque, entre otros factores, en los terrenos agrícolas las fronteras entre campos adyacentes son relativamente estables mientras que los cultivos cambian.

3.2.- OBTENCIÓN DE DATOS DE ENTRENAMIENTO

El objetivo de esta fase es proveer al algoritmo de aprendizaje inductivo de muestras sobre los conceptos que debe aprender. La calidad y la cantidad de los datos que se faciliten al algoritmo va a condicionar, en gran medida, la calidad del modelo aprendido por el algoritmo.

Cada uno de los ejemplos estará descrito por un vector de atributos que expresa los valores de varias características del objeto, siendo una de ellas la clase a la que pertenece.

Las clases de usos del suelo mayoritarias en la zona de estudio son: cítricos, frutales de secano, cultivos hortícolas, matorral, suelo no cultivado, edificios y masas de agua.

Se seleccionaron 250 parcelas (un 5% del total) para entrenamiento del clasificador y la misma cantidad para la evaluación de la clasificación.

Dada la heterogeneidad de las parcelas citrícolas, se definieron tres subclases: *cítricos jóvenes, adultos* e *irregulares*, que posteriormente a la clasificación se fundieron en la clase *cítricos*.

3.3.- CARACTERÍSTICAS CALCULADAS PARA CADA UNA DE LAS PARCELAS

El área de la imagen correspondiente a cada parcela se analiza de forma independiente y de ella se extrae un conjunto de características descriptivas del uso o cultivo existente. Estas características las hemos clasificado en tres grupos:

- Espectrales: Proporcionan información sobre la respuesta espectral de las parcelas, la cual viene dada en función de los tipos de cobertura, estados fisiológicos de las plantas, materiales de construcción, etc. Se calculó la media y la desviación típica del valor de intensidad en las 3 bandas espectrales utilizadas: verde, rojo e infrarrojo cercano, y del índice NDVI.
- De *textura*: Aportan información acerca de la distribución espacial de los valores de intensidad en la imagen. Se calculan teniendo en cuenta ciertos vecindarios o entornos alrededor de cada píxel. Así, por ejemplo, permiten cuantificar propiedades como la heterogeneidad, el contraste o la uniformidad de las distintas zonas de una imagen, las cuales varían en función del uso de cada parcela.

Se calculó la matriz de coocurrencias de niveles de gris y de ella se extrajeron las características de

uniformidad, contraste, entropía, media, varianza, covarianza, correlación y momento diferencia inverso. También se han calculado otros indicadores texturales como la energía, la intensidad de bordes y la curtosis y el coeficiente de asimetría del histograma de la imagen. Una descripción completa de estos parámetros puede encontrarse en Ruiz et.al., (2004).

- Estructurales: Son variables relacionadas con los patrones de distribución de los elementos de una parcela (árboles, por ejemplo) y dan información sobre su disposición en forma regular, formando líneas, marcos definidos, o por el contrario se disponen aleatoriamente en el espacio.

3.4.- MÉTODOS PARA LA EXTRACCIÓN DE CARACTERÍSTICAS ESTRUCTURALES

El marco de plantación que se utiliza en los cultivos arbóreos es una de las características más significativas para la identificación visual de este tipo de cultivos. La colocación de los árboles siguiendo patrones geométricos, bien sea en cuadrados, rectángulos, al tresbolillo, hileras etc. supone una ayuda fundamental para la correcta fotointerpretación de los distintos cultivos.

El primer paso planteado en la extracción de información estructural consiste en la identificación de árboles individuales. Para ello, se ha calculado el valor máximo local del NDVI en vecindarios con un tamaño equivalente al marco de plantación medio de las plantaciones arbóreas presentes en la zona. Así, el filtrado se realizó con un tamaño de ventana de 5x5 píxeles, de acuerdo al tamaño medio de los árboles presentes en la zona de estudio. De esta forma, en la posición de la copa del árbol (mayor densidad de vegetación) es de esperar que se obtengan los valores máximos, salvo casos anómalos. En ocasiones, el máximo de reflectancia está desplazado hacia el sur debido a la posición del sol en el momento de la toma de la imagen. Se definió un umbral mínimo de NDVI, por debajo del cual se rechazaron los máximos existentes en zonas sin vegetación.

Como resultado obtenemos una imagen de máximos, de tal forma que las parcelas con cultivos arbóreos presentarán una malla regular, mientras que en el resto de las parcelas será aleatoria. En aquellas parcelas que no contengan vegetación es posible que también aparezcan máximos, pero dispuestos de forma no regular, por lo que podrán ser detectados posteriormente.

Una vez identificados los árboles individuales, se procede a la <u>identificación de patrones de distribución regular</u> en cada parcela. Para ello, se combinan dos métodos de análisis: a) la transformada de Hough, y b) el semivariograma experimental. A continuación describimos brevemente ambos:

1. Análisis de la transformada de Hough:

Consiste en la transformación de las coordenadas de la imagen desde el sistema cartesiano X e Y, a un sistema de coordenadas polares ρ y θ . En este nuevo espacio de representación, analizando uno a uno los máximos dentro de cada parcela, resulta más sencilla comprobar si se ajustan a la ecuación de una recta, fijando unos parámetros mínimos que deben cumplirse (número mínimo de puntos alineados, etc.). Así, se obtiene un conjunto de posibles alineaciones como se muestra en la figura 2. Además, al disponer de la dirección (θ) y de la posición respecto al origen (ρ) de cada recta, pueden identificarse la dirección o direcciones dominantes de alineación de cada parcela (figura 3) y la distancia entre las alineaciones con la misma dirección, consiguiendo así los marcos de plantación.

Las variables calculadas para cada parcela en esta fase son: dirección principal, porcentaje de árboles en la dirección principal, dirección secundaria, porcentaje de árboles en la dirección secundaria, diferencia entre dirección principal y secundaria, distancias al origen de la dirección principal y de la dirección secundaria.

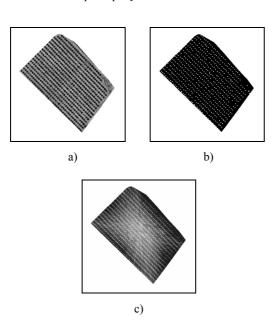


Figura 2.- Ejemplo de la transformada de Hough: a) imagen CIR original; b): identificación de máximos asociados con la posición de los árboles; c) extracción de rectas mediante la transformada de Hough

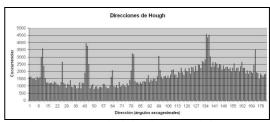


Figura 3.- Frecuencia de las direcciones de las rectas localizadas

2. Análisis del semivariograma experimental: Ya que la característica principal definitoria de los marcos de plantación es su regularidad según un determinado patrón geométrico, se decidió utilizar herramientas geoestadísticas para caracterizar estos patrones regulares en el espacio.

El semivariograma es una función que relaciona la varianza (semivarianza) de una variable con su separación espacial, proporcionando una descripción cuantitativa del patrón de variabilidad espacial. El semivariograma experimental se define mediante la expresión (1):

$$\gamma(h) = \frac{1}{2N} \sum_{i=1}^{N} \left[Z(x_i) - Z(x_i + h) \right]^2$$
 (1)

donde $Z(x_i)$ representa el valor de la variable en la posición x_i , N es el número de elementos considerados, y h nos da la distancia entre elementos en una dirección particular.

Al observar el semivariograma multidireccional calculado sobre la banda de infrarrojo, se puede apreciar que en las parcelas con una disposición no regular de los árboles, la forma del semivariograma es una curva ascendente que se estabiliza a una cierta distancia del origen (ver fig 4).

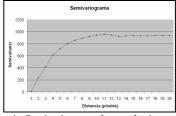


Figura 4.- Semivariograma de parcela sin marco de plantación

Por otra parte, aquellas parcelas cuyos árboles siguen una disposición regular, tienen un semivariograma con un valor mínimo bien definido, es decir, a una distancia entre árboles la varianza es mínima, ya que existe una repetición del valor inicial.

Las características obtenidas en este proceso son: valor y posición del primer máximo, valor y posición del primer mínimo, valor y posición del segundo máximo,

pendiente entre el primer máximo y el primer mínimo y pendiente entre el segundo máximo y el primer mínimo. (ver fig. 5)

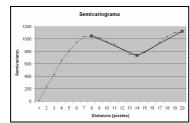


Figura 5.- Semivariograma de parcela con marco de plantación bien definido.

3.5.- CLASIFICACIÓN MEDIANTE ÁRBOLES DE DECISIÓN

Un árbol de decisión es un conjunto de condiciones organizadas en una estructura jerárquica, de tal manera que la clase a asignar a un objeto se puede determinar siguiendo las condiciones que se cumplen desde la raíz del árbol hasta alguna de sus hojas.

| Clase 1 | Clase 2 | Clase 3 | Clase 4 | Clase 1 | Clase 2 | Clase 3 | Clase 1 | Clase 1 | Clase 2 | Clase 3 | Clase 1 | Clase 1 | Clase 2 | Clase 3 | Clase 4 | Clase 1 | Clase 1 | Clase 3 | Clase 4 | Clase 1 | Clase 4 | Clase 1 | Clase 3 | Clase 4 | Clase 4 | Clase 4 | Clase 4 | Clase 5 | Clase 6 | Clase 7 | Cla

Figura 6.- Árbol de decisión

Para construir un árbol de decisión se parte de un conjunto de ejemplos de los que se conoce la clase a la que pertenecen. Este conjunto de ejemplos se va dividiendo utilizando un conjunto de condiciones excluyentes entre sí. Cada uno de estos subgrupos de ejemplos se va dividiendo hasta llegar a generar subgrupos donde todos los elementos pertenecen a la misma clase. Estos algoritmos se basan en buscar particiones que consigan subgrupos de datos más puros, menos mezclados que el conjunto de datos anterior del que provienen. Para cada división posible del conjunto de datos iniciales según una determinada condición, se calcula el grado de impureza de los subconjuntos generados y se selecciona aquella condición que proporciona un grado de impureza menor. El algoritmo se repite de forma iterativa hasta conseguir dividir el conjunto de datos iniciales en subconjuntos homogéneos.

Una vez obtenido el árbol de decisión, se puede convertir en reglas, cuyo cumplimiento implica la asignación de los objetos de partida a la clase correspondiente. El objetivo de estos métodos de clasificación no sólo es desarrollar clasificadores precisos, sino además conseguir que el modelo sea inteligible para las personas. El algoritmo utilizado es conocido como C5 y facilita la comprensión de los árboles de decisión ya que traduce el modelo aprendido en un conjunto de *reglas de producción* más inteligibles que los árboles (Quinlan, 1993). Este algoritmo utiliza de forma iterativa una estrategia llamada "divide y vencerás".

El criterio de selección del atributo está basado en la medida de la entropía, donde en cada nodo el atributo con la mínima entropía se selecciona para dividir el conjunto de datos.

Una de las ventajas de los árboles de decisión es que realizan de forma implícita un proceso de selección de las variables más significativas. Por lo tanto, una vez construido el árbol, aquellos atributos que no intervienen en ninguna condición pueden descartarse, reduciéndose el tamaño del espacio de características descriptivas de los objetos.

Las ventajas principales de los árboles de decisión son las siguientes: (Hernández Orallo, 2004)

- Son aplicables a distintas tareas: clasificación, regresión, agrupamiento, etc...
- Tratan con atributos continuos y discretos.
- Son flexibles. No hacen ninguna suposición sobre la distribución de los datos, al contrario de lo que hacen algunos métodos estadísticos. Esta característica permite incorporar datos discretos a la clasificación de imágenes, independientemente de la distribución y la correlación que exista entre ellos.
- Son fáciles de usar.
- Son tolerantes al ruido, a atributos no significativos y a valores faltantes.
- Las condiciones extraídas son inteligibles por el usuario.
- Existe software para su aplicación y en algunos casos es gratuito.

La clasificación de los objetos de la imagen no se realizó con un único árbol de clasificación, sino con diez árboles aplicando el método multiclasificador boosting que permite aumentar la precisión de las clasificaciones (Freund, 1995). El método boosting sirve para minimizar la sensibilidad de un algoritmo de clasificación, un árbol de decisión en nuestro caso, a los posibles errores existentes en las características de los datos de entrada al clasificador, así como a los posibles errores de clasificación en los datos de entrenamiento.

La sistemática que sigue *boosting* (Freund y Schapire, 1997; Quinlan, 1996) para construir el multiclasificador consiste en asignar un peso a cada muestra del conjunto de entrenamiento. Cuanto mayor sea el peso de una muestra, mayor será su influencia en el clasificador.

Tras cada iteración, es decir, en la construcción de cada árbol o modelo, el vector de pesos se ajusta para reflejar el rendimiento del modelo, de modo que las muestras erróneamente clasificadas ven incrementados sus pesos, mientras que se reducen los pesos de los ejemplos clasificados correctamente. De esta forma se consigue que el modelo que se aprenda en la iteración siguiente dé más relevancia a las muestras erróneamente clasificadas anteriormente (Hernández Orallo, 2004). Una vez realizados los distintos modelos, la clase asignada a un objeto será la más frecuente entre las predicciones de los árboles de decisión.

4.- RESULTADOS

La evaluación de la clasificación se realizó mediante la comparación de la clase real y la predicha por el clasificador, de un muestreo aleatorio de parcelas (5% del total). La fiabilidad global de la clasificación es del 88.2%.

El análisis de la matriz de confusión (ver Tabla 2) de la clasificación indica que los cultivos arbóreos, tanto cítricos como frutales de secano que son tipologías de cultivo especialmente complejas, donde la respuesta espectral de cada parcela es combinación de la respuesta del suelo y de la vegetación, son detectados con una fiabilidad alta siempre mayor al 85% y con escasa confusión entre ambas.

		CLASE PREDICHA POR EL SISTEMA								
		Agua	Citricos	Edificios	Frutales Secano	Matorral	Horticolas	Suelo Desnudo	Total	Fiabilidad Usuario
CLASE REAL	Agua	5		1					- 6	83.33%
	Citricos		85		1		3	6	95	89.47%
	Edificios			8				2	10	80%
	Frut.Sec		4		52				56	92.86%
	Matorral					- 4			4	100%
	Horticolas					1	17	2	20	85%
	S.Desnudo				7		3	53	63	84.13%
	Total	5	89	9	60	5	23	63	254	
	Elich Dec d	1.000/	06 60/	00 000/	96.669/	9/00/	72.010/	04 120/		

Tabla 2.- Matriz de confusión

El error existente en la clasificación de una masa de agua como edificio se debe a la delimitación errónea en la cartografía de esa masa de agua, que implica la inclusión de píxeles externos a la masa de agua en el análisis.

5.- CONCLUSIONES

Las técnicas de clasificación orientada a objetos permiten la combinación de información vectorial con imágenes, siendo de especial interés en aquellos casos en los que se desea actualizar cartografía a partir de una base vectorial existente y de una serie de ortoimágenes actuales. Además, permiten extraer información espectral, de texturas o estructural específica de cada parcela.

Los árboles de decisión ofrecen la posibilidad de seleccionar el conjunto de variables óptimo y de realizar múltiples iteraciones en las clasificaciones, aportando una mayor robustez y flexibilidad al proceso.

El algoritmo C5 crea árboles de decisión muy ajustados a las muestras de aprendizaje. Por tanto, es necesaria una selección muy cuidadosa de las mismas y utilizar algún método de poda para evitar el sobreajuste a los datos.

Los resultados obtenidos son satisfactorios teniendo en cuenta la elevada variabilidad existente dentro de cada clase de parcelas considerada. Mediante la inclusión de nuevas variables y tipos de información se puede pensar en la resolución de problemas de clasificación y actualización cartográfica más complejos.

Las discrepancias de georreferenciación entre la imagen y la cartografía, producen errores de clasificación más notorios en las parcelas de menor tamaño

REFERENCIAS

Antunes, A., Lingnau, C., y Silva Centeno, 2003, Object oriented analysis and semantic network for high resolution image classification. *Boletim de Ciências Geodésicas*, 9, 233-242.

Blaschke, T, Burnett, C., y Pekkarinen, A., 2004 Image Segmentation Methods for Object-based Analysis and Classification. En Remote Sensing Image Analysis: Including the Spatial Domain, editado por De Jong, S.M. y Van der Meer, F.D. (Kluwer Academic Publishers), pp.211-236.

Freund, Y., 1995, Boosting a weak learning algorithm for majority. *Information and Computation*, 121, 256-285

Freund, Y. y Shapire, R. E., 1997, A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55, 119-139.

Hernández Orallo, J., Ramírez Quintana, M. J., y Ferri Ramírez, C., 2004, Introducción a la Minería de Datos (Pearson Educación S.A.).

Quinlan, J. R., 1993, Programs for machine learning (Morgan Kaufmann).

Quinlan, J. R.1996, Bagging, boosting and C4. Proceedings of the 30th National Conference on Artificial Intelligence and the 8th Innovative Applications of Artificial Intelligence, 5, 725-730.

Ruiz, L. A., Fdez.-Sarría, A., y Recio, J. A., 2004, Texture feature extraction for classification of remote sensing data using wavelet decomposition: A comparative study. En International Archives of Remote Sensing and Spatial Information Sciences, XX, 1109-1205.

AGRADECIMIENTOS

Los autores agradecen el apoyo económico al Ministerio de Educación y Ciencia y al FEDER, dentro del proyecto del Plan Nacional de Investigación REN2003-04998.