

## MÉTODOS PARA LA CLASIFICACIÓN AUTOMÁTICA DE FOTOGRAFÍAS AÉREAS HISTÓRICAS EN BLANCO Y NEGRO

EDUARDO CORBELLE RICO<sup>1</sup> y RAFAEL CRECENTE MASEDA<sup>2</sup>

Departamento de Enxeñaría Agroforestal, Universidade de Santiago de Compostela  
Escola Politécnica Superior, Campus Universitario s/n.

27002 Lugo (España)

<sup>1</sup> [eduardo.corbelle@usc.es](mailto:eduardo.corbelle@usc.es) <sup>2</sup> [rafael.crecente@usc.es](mailto:rafael.crecente@usc.es)

### RESUMEN

La fotografía aérea histórica constituye una valiosa fuente de información acerca del uso del territorio en tiempos pasados, cuyas múltiples aplicaciones incluyen el ordenamiento territorial, la arqueología, la investigación de la propiedad, o los estudios de cambio de uso o cobertura del suelo, por ejemplo. Para facilitar el uso de esta información resultaría de gran interés disponer de métodos de clasificación automática que permitan generar mapas históricos de uso o cubierta del suelo. Las posibilidades reales de este tipo de técnicas chocan, sin embargo, con el hecho de tratarse de fotografías en blanco y negro, lo que reduce considerablemente la información disponible para el tratamiento digital. Este trabajo explora algunos de los métodos disponibles para este fin, como la clasificación orientada a objetos o el uso de información textural. Los resultados de fiabilidad obtenidos son necesariamente más bajos que los habituales en el manejo de imágenes multispectrales, pero suficientes para resultar de interés en un entorno operativo.

Palabras clave: usos del suelo, *software* libre, objetos, Sistemas de Información Geográfica.

### METHODS FOR AUTOMATIC CLASSIFICATION OF HISTORICAL BLACK AND WHITE AERIAL PHOTOGRAPHS

#### ABSTRACT

The use of historical aerial photographs allows researchers to access a valuable source of information about past land use, which may be used in multiple applications including land planning, archaeology, property research, or land use / land cover change studies. In order to make these tasks easier, the use of automatic classification methods to create maps of historic land use / land cover would be very interesting. Nevertheless, the real possibilities for these methods to succeed are confronted by the very nature of the black and white photographs and the much reduced

information they contain for digital processing techniques. This paper presents some of the available methods, such as object-oriented classification methods, or the use of textural information. The results show low accuracy values, at least when compared with the use of multispectral images, which nevertheless can be of interest in an operating context.

Keywords: land use, free software, objects, Geographic Information Systems.

## 1. Introducción

El concepto de clasificación de una imagen puede ser definido, de modo extremadamente simple, como la obtención de un mapa temático a partir de ella (Schowengerdt, 2007). La simplicidad de esta definición le permite incluir un número considerable de métodos distintos, incluso la delineación manual de clases de interés. La aparición de las primeras imágenes en formato digital (bien tomadas directamente en formato digital desde alguna plataforma satelital o digitalizadas a partir de fotografías aéreas) condujo a los primeros métodos de clasificación automática. La naturaleza de estos primeros métodos impregna muchas de las definiciones propuestas por otros autores. Este es el caso de la sugerida por Chuvieco (2006), según la cual la clasificación es un proceso por el cual *"la imagen multibanda se convierte en otra imagen del mismo tamaño y características que la original, con la diferencia de que el nivel digital de cada píxel no tiene relación con la radiancia detectada por el sensor, sino que se trata de una etiqueta que identifica la categoría asignada a este píxel"*. Hemos traído a colación esta cita para destacar dos aspectos que nos parecen fundamentales. En primer lugar, la definición asume que la imagen que se clasifica es multibanda, es decir, es el resultado de capturar información de modo separado en diferentes regiones del espectro electromagnético. En segundo lugar, enfatiza la importancia del proceso a nivel de píxel individual, lo que nos remite directamente al modo de operación de los clasificadores tradicionales. En contraste con lo anterior, este trabajo se propone la clasificación de una imagen que no es multibanda sino pancromática y utiliza (en dos de los tres casos propuestos) métodos que se engloban dentro del grupo de los orientados a objetos, que no clasifican píxeles individuales sino grupos de píxeles.

El trabajo que se presenta se plantea como objetivo la evaluación de diferentes métodos posibles para la segmentación de una fotografía aérea, correspondiente al vuelo de la serie B de 1956-1957 sobre una parroquia gallega, con la finalidad de clasificarla en cuatro grandes categorías: a) tierra arable, b) prados, c) matorral y d) arbolado. El trabajo centra su atención en aquellos métodos que mostraron mayor potencial en la revisión bibliográfica, entre ellos dos métodos de clasificación orientada a objetos. Por otra parte se explora la utilidad de la información textural para incrementar la fiabilidad de la clasificación.

## 2. Estado de la cuestión

Las experiencias de clasificación automática de imágenes pancromáticas son relativamente escasas, lo cual no es extraño en absoluto dada la escasa información espectral que contienen. Aun

cuando la resolución espacial de la imagen multispectral sea menor que la de su equivalente pancromática (algo común en las imágenes de satélite), la mayor información espectral contenida en la primera justifica su uso en la clasificación. Sin embargo, en el caso de las fotografías aéreas históricas no existe alternativa multibanda posible, y éste es un nicho que vale la pena cubrir.

La revisión de casos similares en la bibliografía puso de manifiesto que la mayor parte de ellos reducen sus expectativas a la clasificación de dos o tres cubiertas diferentes como máximo: árboles y fondo (Pillai *et al.*, 2005), vegetación leñosa y fondo (Robinson *et al.*, 2008), matorral y fondo (Laliberte *et al.*, 2004; Hutchinson *et al.*, 2000), árboles y dos clases de matorral (Carmel y Kadmon, 1998; Kadmon y Harari-Kremer, 1999), invernaderos y fondo (Agüera *et al.*, 2008). Aún a pesar del reducido número de categorías, la fiabilidad de las clasificaciones resultantes fue relativamente baja, desde el 60% (Carmel y Kadmon, 1998) hasta el 80% (Kadmon y Harari-Kremer, 1999). En algún caso, la fiabilidad se refiere al número de objetos (árboles, parcelas, ...) correctamente identificados y no a la proporción de píxeles: cuando es medida de ese modo la fiabilidad final es mayor, de hasta el 90% (Pillai *et al.*, 2005), pues un árbol identificado supone un acierto aún cuando muchos de sus píxeles (especialmente los situados en los bordes) estén mal clasificados. En algunos casos los autores consideraron necesaria una reclasificación manual posterior (Marignani *et al.*, 2008), lo que evidencia que los resultados no eran suficientemente precisos para los fines previstos, pero no invalida la clasificación automática: la reclasificación manual puede suponer menos esfuerzo que una clasificación manual completa. En todo caso, siempre se cumple la regla general (válida para cualquier tipo de clasificación) de que la separabilidad o grado de solape entre las cubiertas a identificar tiene una importancia fundamental en la calidad final de los resultados, sin importar el método empleado.

En cuanto a los métodos utilizados, encontramos técnicas de segmentación por umbrales o *thresholding* (Laliberte *et al.*, 2004; Hutchinson *et al.*, 2000; Lahav-Ginott *et al.*, 2001), de clasificación orientada a objetos (Laliberte *et al.*, 2004; Pillai *et al.*, 2005; Marignani *et al.*, 2008) y también otras más habituales como la clasificación por máxima verosimilitud (Carmel y Kadmon, 1998; Kadmon y Harari-Kremer, 1999). En algunos casos los autores trataron de mejorar los resultados de la clasificación incorporando información relativa a la textura de la imagen, lo que en ocasiones resultó en una mejora de la fiabilidad final (Carmel y Kadmon, 1998; Cots Folch *et al.*, 2007), pero en otras no (Agüera *et al.*, 2008). La textura es una medida de la frecuencia con la que los niveles digitales de la imagen varían respecto de sus vecinos y puede ser evaluada con diferentes métodos, si bien resulta habitual que se derive de la matriz de coocurrencias de gris (*grey level co-occurrence matrix*, GLCM) definida por Haralick *et al.* (1973). El uso de medidas de textura para incrementar la fiabilidad de la clasificación no es exclusivo de los trabajos con imagen pancromática, sino que también ha sido empleado con éxito con imágenes multispectrales (Johansen *et al.*, 2007).

Finalmente, algunos autores detectaron la necesidad de realizar correcciones radiométricas previas a la clasificación, en particular debido a la variación del brillo en sentido radial desde el centro hacia los bordes de la fotografía (Carmel y Kadmon, 1998). Los mismos autores exploraron la corrección del efecto de la topografía en las variaciones de brillo en la fotografía (por el diferente ángulo de reflexión asociado a cada pendiente), pero no obtuvieron mejoras con este procedimiento.

Por otra parte, con el fin de reducir el efecto de "sal y pimienta" resultante en las clasificaciones *píxel a píxel*, se emplearon tanto el suavizado previo a la clasificación mediante filtros de paso bajo (Laliberte *et al.*, 2004) como la aplicación de filtros de mayoría al resultado final (Cots Folch *et al.*, 2007).

### 3. Materiales, datos y métodos

#### 3.1. Material utilizado

La fotografía empleada en este trabajo procede del vuelo de la serie B correspondiente a los años 1956 y 1957 (escala de vuelo 1:30.000). En concreto, se trata de un fotograma correspondiente a la pasada 15 de la provincia de Lugo, en el término municipal de Begonte, ya ortorrectificado (con un error medio cuadrático estimado, mediante puntos de comprobación independientes, de 5 m.) y con una resolución espacial de 60 cm./píxel ([figura 1](#)). En la elección del fotograma se procuró que cubriese una zona con cubiertas del suelo mezcladas entre sí, con la idea de representar una situación lo más parecida posible a la que caracterizaría un entorno operativo.

Para aplicar los diferentes métodos de segmentación y clasificación se utilizó el *software* de clasificación eCognition v. 4 (Definiens Imaging, 2004), el Sistema de Información Geográfica libre GRASS (GRASS Development Team, 2008; Neteler y Mitasova, 2004), el paquete estadístico libre R (R Development Core Team, 2008) y la interfaz entre los dos últimos desarrollada por Bivand (2008) a través del paquete de R "spgrass6".

#### 3.2. Comprobaciones de la radiometría

Siguiendo el ejemplo de alguno de los trabajos consultados en la bibliografía (Carmel y Kadmon, 1998), realizamos una comprobación para detectar la posible existencia de variaciones de brillo en sentido radial en la fotografía. Para la comprobación se recurrió al fotograma original en lugar de al producto ortorrectificado y se midió el nivel de gris de 100 píxeles diferentes, correspondientes a la cubierta "tierra arable", registrando para cada píxel la distancia que lo separaba del punto principal (centro) del fotograma. Los resultados obtenidos no inducen a pensar que existan variaciones sistemáticas de brillo entre el centro y los bordes del fotograma (pues no se observa correlación entre los niveles digitales y su distancia al centro principal de la fotografía), por lo que no hay necesidad de aplicar una corrección en este sentido.

### 3.3. Métodos de clasificación

#### 3.3.1. Segmentación por umbrales

La segmentación por umbrales o *thresholding* es un método muy simple desde el punto de vista conceptual. Su aplicación más elemental es la de "binarizar" imágenes: separar el primer plano del fondo utilizando para ello un valor de nivel digital utilizado como umbral (*threshold*). Existen diferentes variantes en función de si se consideran primer plano a los píxeles que superen el valor del umbral, los que no lo superen o los que estén comprendidos entre dos valores (Shapiro y Stockman, 2001). Dado que el objetivo de este trabajo es dividir la imagen en cuatro clases, se hace necesario definir tres umbrales.

La elección de los valores para ser utilizados como umbral es la parte más compleja de este método, para la que existen varias opciones posibles. Una de ellas sería utilizar como umbral los puntos de ruptura presentes en el histograma de la imagen, pero estos puntos de ruptura no siempre existen. La ausencia de una división más o menos clara en el histograma también impide utilizar métodos automáticos, porque la mayoría de ellos están pensados específicamente para localizar el punto donde la división se produce (Shapiro y Stockman, 2001). Una última opción consiste en seleccionar los valores de umbral a partir del conocimiento que se tenga de las diferentes cubiertas a identificar, incluso variando los valores sucesivamente hasta conseguir que los resultados se acerquen a lo que sería deseable (*knowledge-based thresholding*, Shapiro y Stockman, 2001). Esta última opción es la utilizada en este trabajo, utilizando la información extraída de un conjunto de áreas de muestra de cada una de las clases a identificar, seleccionadas para representar lo mejor posible las variaciones internas de cada una existentes en la fotografía. Los niveles digitales presentes en cada clase se representaron en forma de histograma ([figura 2](#)): como se puede apreciar, la clase "tierra arable" es la que mejor se diferencia de las demás al aparecer en la fotografía con tonos muy claros. Las clases "arbolado" y "prados", por otra parte, muestran un cierto grado de solape entre sí dado que los prados, con mayor humedad, aparecen en la fotografía en tonos considerablemente oscuros, ofreciendo en la imagen un tono incluso más oscuro que algunas de las masas arboladas. La clase que presenta un mayor solape con las demás es la de "matorral": esta clase incluye áreas en las que el terreno desnudo o con muy poca vegetación alterna con matas más o menos densas y que, por tanto, aparecen en la fotografía con tonos que van de los más oscuros, correspondientes a sombras y matas espesas de matorral, a los más claros, correspondientes al suelo desnudo o poco cubierto. Parece obvio que a partir de los histogramas representados en la figura es posible utilizar diferentes criterios para establecer umbrales de segmentación: en este trabajo optamos por utilizar como umbral aquel nivel digital a partir del cual la frecuencia de una de las clases supera a las contiguas. De este modo, para un determinado nivel digital en la fotografía, se asigna a cada píxel aquella clase a la que la probabilidad de pertenencia es mayor: para niveles digitales menores de 90 se asigna la clase "arbolado"; para niveles digitales entre 90 y 135 la clase "prados"; entre 135 y 160, la clase "matorral" y cuando el nivel digital es mayor de 160, la clase "arable".

### 3.3.2. Clasificación orientada a objetos

Bajo el nombre genérico de métodos orientados a objetos se incluyen todos aquellos que, al contrario que los métodos de clasificación tradicionales (*pixel a pixel*), no solamente tienen en cuenta el nivel digital de cada píxel sino los de los píxeles vecinos. Teóricamente, una aproximación orientada a objetos se corresponde mejor con la realidad ya que las cubiertas del suelo ocupan (en las imágenes de alta resolución) áreas de mayor entidad que un píxel y, por tanto, es preferible clasificar estas áreas u objetos tomándolos como una sola unidad. Ahora bien, las múltiples posibilidades de segmentación de la imagen dan lugar a otros tantos métodos posibles de clasificación. En este trabajo se utilizan dos métodos que representan dos aproximaciones muy diferentes y están disponibles en paquetes informáticos con una filosofía y orientación también distintas. El primero de ellos, que recibe el nombre de *Sequential Maximum a Posteriori estimation* (SMAP), está implementado en el Sistema de Información Geográfica GRASS y pertenece al grupo de métodos que realizan la segmentación a partir de la información proporcionada por el usuario (*knowledge driven*) en forma de áreas de entrenamiento. El modo de operación de SMAP consiste en dividir la imagen a varias escalas y utilizar las divisiones a escala más gruesa para guiar la clasificación de los objetos definidos a escalas más finas, siempre teniendo como referencia las características espectrales de cada clase definidas por las áreas de entrenamiento (Bouman y Shapiro, 1992, 1994; McCauley y Engel, 1995). El segundo método, implementado en el paquete comercial eCognition, recibe el nombre de *Fractal Net Evolution Approach* (FNEA, Definiens Imaging, 2004) y representa la estrategia opuesta (*data driven*): el algoritmo segmenta la imagen atendiendo a criterios de color, forma y escala, y deja para una segunda fase la tarea de decidir si los objetos generados se corresponden o no con categorías del mundo real. En caso negativo, se procedería con una nueva segmentación y, en caso afirmativo, es posible seleccionar algunos de esos objetos como áreas de entrenamiento a partir de las cuales clasificar al resto. Este último se presenta como un método más complejo que SMAP por cuanto requiere que el usuario defina parámetros de escala, forma y compacidad para la segmentación, pero por lo mismo tiene el potencial de generar mejores resultados. Entre las ventajas teóricas de FNEA figuran la posibilidad de generar objetos a diferentes escalas y establecer reglas de pertenencia entre los diferentes niveles, o la de utilizar diferentes fuentes de información en las fases de segmentación y clasificación. Los parámetros de segmentación se obtienen mediante prueba y error: en este caso, se observó cómo un valor del parámetro de escala (adimensional) de 50 era el más adecuado (valores mayores generaban objetos con cubiertas mezcladas y valores menores generaban segmentaciones excesivamente complejas); los valores de los restantes parámetros que se comprobaron como más eficaces en este caso fueron 0,1 para el de forma y 0,8 para el de compacidad, ambos definidos igualmente mediante pruebas sucesivas e inspección visual de los segmentos generados.

### 3.4. Información textural

Dado que la respuesta espectral de las diferentes cubiertas muestra un solape considerable, es de esperar que las clasificaciones basadas exclusivamente en la información espectral de la fotografía presenten altos valores de confusión entre clases. Precisamente una de las causas de la existencia de ese solape es la heterogeneidad de la clase "matorral", que hace que los píxeles de esa cubierta presenten niveles digitales muy diferentes entre sí. Esta circunstancia se refleja en una

textura más gruesa que en el resto de las clases, que podría ser utilizada para contribuir a una mejor discriminación del matorral respecto de las otras cubiertas. Para explorar esta posibilidad se utilizó la capacidad de GRASS para obtener diferentes variables de textura a partir de la imagen original. Observamos que un suavizado previo (en este caso un filtro de media con tamaño de ventana de 5 píxeles) contribuía a eliminar parte del ruido presente en la imagen y realzar así las diferencias de textura entre cubiertas. El módulo "r.texture" de GRASS permite calcular hasta 14 medidas de textura diferentes, de las cuales aquélla que respondía mejor a nuestros objetivos fue la varianza entre píxeles vecinos, calculada con un tamaño de ventana de 5 píxeles ([figura 3](#)). Valores menores de ventana no permitían apreciar diferencias entre cubiertas, y valores mayores realizaban de un modo exagerado el efecto de borde entre diferentes cubiertas. Las características de funcionamiento de los dos algoritmos de clasificación condicionaron el modo de empleo de la información textural: ya que FNEA realiza la segmentación y clasificación en dos fases separadas, permite realizar la primera sobre la imagen original e incorporar, posteriormente, la información textural en el proceso de clasificación; por el contrario, SMAP no permite separar los dos procesos por lo que la incorporación de información textural requiere necesariamente que también la segmentación se realice conjuntamente sobre ambas imágenes.

#### 4. Resultados

La calidad final de las clasificaciones obtenidas (segmentación por umbrales, FNEA y SMAP con y sin información textural, [figura 4](#), [figura 5](#), [figura 6](#), [figura 7](#), [figura 8](#)) fue evaluada por el procedimiento clásico de la matriz de confusión (Chuvieco, 2006). Para este fin, un conjunto de 200 puntos generados aleatoriamente sobre la imagen fue fotointerpretado de manera manual y los valores obtenidos fueron comparados con los resultantes de cada clasificación. Las matrices ([tabla 1](#), [tabla 2](#), [tabla 3](#), [tabla 4](#) y [tabla 5](#)) incluyen los valores de fiabilidad de productor y usuario, la fiabilidad global y el estadístico  $\kappa$  de Cohen.

Los valores de fiabilidad global de los diferentes métodos ensayados (la proporción de píxeles correctamente identificados en cada caso) toma en todos los casos valores cercanos al 60%. Destaca el hecho de que la fiabilidad global más elevada corresponde al método menos complejo (segmentación por umbrales). Esta aparente ventaja se matiza cuando se consideran las fiabilidades de productor y usuario que cada uno de los métodos ofrece para las diferentes clases: la clase "tierra arable" aparece claramente mejor identificada en la segmentación por umbrales (hasta el 75% de su superficie se clasifica correctamente), pero ésta solo identifica correctamente la clase "matorral" en el 16% de los casos frente al 66% del método SMAP con información de textura. La baja fiabilidad de la segmentación por umbrales ([figura 4](#)) a la hora de identificar las zonas de matorral se aprecia visualmente al comparar sus resultados con los FNEA o SMAP utilizando información textural ([figura 7](#) y [figura 8](#)).

La incorporación de la información textural, efectivamente, incrementa la fiabilidad de productor de la clase "matorral", tanto para el método FNEA como para el SMAP, a costa de degradar en ambos casos la fiabilidad con la que se identifican las clases "tierra arable" y "arbolado". Visualmente, además, la información textural introduce un cierto efecto de borde en la clasificación SMAP ya que los valores más altos de varianza asociados a la clase de "matorral" se

confunden con los valores altos de varianza asociados a la transición entre cubiertas contiguas. Este efecto de borde no aparece, sin embargo, en la clasificación con FNEA ya que en esta última la segmentación se realizó exclusivamente sobre la imagen original.

## 5. Discusión

Los resultados obtenidos en la clasificación de fotografías aéreas pancromáticas muestran, como es lógico, valores de fiabilidad global menores que los habituales en clasificación de imágenes multiespectrales. El número y separabilidad de las clases a identificar también condiciona la bondad de los resultados que se pueden obtener. Teniendo en cuenta que pocos trabajos han enfrentado la clasificación de cuatro cubiertas diferentes exclusivamente a partir de la fotografía en blanco y negro, y también el alto grado de solape que presenta una de las clases con las demás, una fiabilidad del 60% está en línea con los valores observados en la bibliografía. Podemos aventurar que se trata de un umbral de fiabilidad que difícilmente pudiera ser superado, en este caso particular y con las condiciones específicas de las clases definidas, por cuanto no existen diferencias apreciables de fiabilidad total entre los diferentes métodos utilizados. Las diferencias entre métodos son más marcadas desde el punto de vista visual, en el sentido de que las clasificaciones orientadas a objetos generan manchas más uniformes y no acusan el efecto de "*sal y pimienta*" característico de las clasificaciones por píxel (y en este caso de la clasificación por umbrales). Y por otra parte, la incorporación de información textural permite una mejor separación de la clase "matorral", si bien es cierto que con la introducción de más confusión en las clases restantes. También desde el punto de vista visual, se aprecia que el hecho de que FNEA admita incorporar la textura en una fase posterior a la segmentación produce una clasificación de aspecto más limpio (menor presencia de manchas de muy pequeña dimensión, similares al efecto de "*sal y pimienta*") que la resultante de SMAP.

La utilización de información textural se confirma como una posibilidad de mejora de los resultados de la clasificación, si bien es difícil proponer una determinada variable textural como óptima: la enorme variedad de medidas disponibles (que, a su vez, pueden ser calculadas con tamaños de ventana diferentes y ser sometidas a tratamientos previos o posteriores también diversos) se une a la diversidad de situaciones que se pueden encontrar en la imagen original, con lo que resulta muy difícil indicar una combinación recomendable, con carácter general, en todos los casos.

## 6. Conclusiones

Se presentan varias técnicas posibles para realizar la clasificación automática de fotografías aéreas en blanco y negro, todas ellas con resultados globales similares pero con diferencias importantes de calidad visual de sus resultados y de fiabilidad de identificación de cada una de las cubiertas. Es evidente que un estudio comparativo de esta naturaleza no puede equivaler a un ensayo concienzudo de todas las posibilidades de cada técnica: en particular, parece evidente que el *software* comercial eCognition presenta capacidades no exploradas en este trabajo, como la segmentación multiescala o la incorporación de criterios de forma, área o vecindad en la

clasificación de los objetos, y que por lo tanto es potencialmente capaz de ofrecer resultados algo superiores a los mostrados aquí. Por otra parte, también resulta interesante comprobar como existen métodos de clasificación disponibles de manera libre y gratuita (el caso de GRASS es significativo pero no el único) cuyos resultados no son necesariamente inferiores a los aportados por sus homólogos comerciales y que, por tanto, cada equipo de investigación tiene ante sí la oportunidad de decidir si los resultados potencialmente superiores de estos últimos compensan o no su elevado coste económico.

### Referencias bibliográficas

- Agüera, F., Aguilar, F. J. y Aguilar, M. A. (2008): "Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses", *ISPRS Journal of Photogrammetry and Remote Sensing*, 63, 6, pp. 635-646.
- Bivand, R. (2008): *Spgrass6: Interface between GRASS 6 geographical information system and R*. R package version 0.5-3.
- Bouman, C. y Shapiro, M. (1992): "Multispectral image segmentation using a multiscale image model", *Proc. of IEEE International Conference on Acoustics, Speech and Signal Processing*, San Francisco, California, pp. III-565-568.
- Bouman, C. y Shapiro, M. (1994): "A multiscale random field model for bayesian image segmentation", *IEEE Transactions on Image Processing*, 3, 2, pp. 162-177.
- Carmel, Y. y Kadmon, R. (1998): "Computerized classification of Mediterranean vegetation using panchromatic aerial photographs", *Journal of Vegetation Science*, 9, pp. 445-454.
- Chuvieco Salinero, E. (2006): *Teledetección ambiental. La observación de la Tierra desde el espacio*. Barcelona, Ariel.
- Cots Folch, R., Atkinhead, M. J. y Martínez Casanovas, J. A. (2007): "Mapping land cover from detailed aerial photography data using textural and neural network analysis", *International Journal of Remote Sensing*, 28, 7, pp. 1625-1642.
- Definiens Imaging (2004): *eCognition professional v. 4 User Guide*.
- GRASS Development Team (2008): *Geographic Resources Analysis Support System (GRASS GIS) Software*. EEUU, Open Source Geospatial Foundation.
- Haralick, R. M., Shanmugam, K. y Dinstein, I. (1973): "Textural features for image classification", *IEEE Transactions on Systems, Man and Cybernetics*, 3, 6, pp. 610-621.
- Hutchinson, C. F., Unruh, J. D. y Bahre, C. J. (2000): "Land use vs. climate as causes of vegetation change: a study in SE Arizona", *Global Environmental Change*, 10, pp. 47-55.
- Johansen, K., Coops, N. C., Gergel, S. E. y Stange, Y. (2007): "Application of high spatial resolution satellite imagery for riparian and forest ecosystem classification", *Remote Sensing of Environment*, 110, pp. 29-44.
- Kadmon, R. y Harari-Kremer, R. (1999): "Studying long-term vegetation dynamics using digital processing of historical aerial photographs", *Remote Sensing of Environment*, 68, pp. 164-176.
- Lahav-Ginott, S., Kadmon, R. y Gersani, M. (2001): "Evaluating the viability of *Acacia* populations in the Negev Desert: a remote sensing approach", *Biological Conservation*, 98, 2, pp. 127-137.
- Laliberte, A. S., Rango, A., Havstad, K. M., Paris, J. F., Beck, R. F., McNeely, R. y González, A. L. (2004): "Object-oriented image analysis for mapping shrub encroachment from 1937 to 2003 in southern New Mexico", *Remote Sensing of Environment*, 93, 2, pp. 198-210.

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157

---

Marignani, M., Rocchini, D., Torri, D., Chiarucci, A. y Maccherini, S. (2008): "Planning restoration in a cultural landscape in Italy using an object-based approach and historical analysis", *Landscape and Urban Planning*, 84, 1, pp. 28-37.

McCauley, J. D. y Engel, B. A. (1995): "Comparison of scene segmentations: SMAP, ECHO and Maximum Likelihood", *IEE Transactions on Geoscience and Remote Sensing*, 33, 6, pp. 1313-1316.

Neteler, M. y Mitasova, H. (2004): *Open source GIS: a GRASS GIS approach (2ª ed.)*. New York, Springer.

Pillai, R. B., Weisberg, P. J. y Lingua, E. (2005): "Object-oriented classification of repeat aerial photography for quantifying woodland expansion in central Nevada", *20th Biennial Workshop on Aerial Photography, Videography, and High Resolution Digital Imagery for Resource Assessment, Weslaco, Texas*.

R Development Core Team (2008): *R: A Language and Environment for Statistical Computing*. Vienna, Austria: R Foundation for Statistical Computing. ISBN 3-900051-07-0.

Robinson, T.P., van Klinken, R. D. y Metternicht, G. (2008): "Spatial and temporal rates and patterns of mesquite (*Prosopis* sp) invasion in Western Australia", *Journal of Arid Environments*, 72, 3, pp. 175-188.

Schowengerdt, R. A. (2007): *Remote sensing. Models and methods for image processing (3ª ed.)*. Burlington, Academic Press.

Shapiro, L. G. y Stockman, G. C. (2001): *Computer vision*. New Jersey, Prentice Hall.

## TABLAS

**Tabla 1. Matriz de confusión: segmentación por umbrales**

Clasificación	Referencia				Fiab. usuario	Fiab. productor
	Arable	Prados	Matorral	Arbolado		
Arable	48	2	1	0	94,1%	75,0%
Prados	2	26	11	4	60,5%	51,0%
Matorral	12	6	5	1	20,8%	15,6%
Arbolado	2	17	15	46	57,5%	90,2%

Fiabilidad global: 62,5%. Kappa de Cohen: 0,491.

**Tabla 2. Matriz de confusión: SMAP sin información textural**

Clasificación	Referencia				Fiab. usuario	Fiab. productor
	Arable	Prados	Matorral	Arbolado		
Arable	40	1	1	0	95,2%	60,6%
Prados	4	25	9	4	59,5%	49,0%
Matorral	20	8	7	1	19,4%	21,9%
Arbolado	2	17	15	46	57,5%	90,2%

Fiabilidad global: 59,0%. Kappa de Cohen: 0,451.

**Tabla 3. Matriz de confusión: FNEA sin información textural**

Clasificación	Referencia				Fiab. usuario	Fiab. productor
	Arable	Prados	Matorral	Arbolado		
Arable	48	2	1	0	94,1%	72,7%
Prados	1	15	9	4	51,7%	29,4%
Matorral	15	14	10	4	23,3%	31,3%
Arbolado	2	20	12	43	55,8%	84,3%

Fiabilidad global: 58,0%. Kappa de Cohen: 0,437.

**Tabla 4. Matriz de confusión: SMAP con información textual**

Clasificación	Referencia				Fiab. usuario	Fiab. productor
	Arable	Prados	Matorral	Arbolado		
Arable	40	1	0	0	97,6%	60,6%
Prados	2	18	1	0	85,7%	35,3%
Matorral	24	19	21	11	28,0%	65,6%
Arbolado	0	13	10	40	63,5%	78,4%

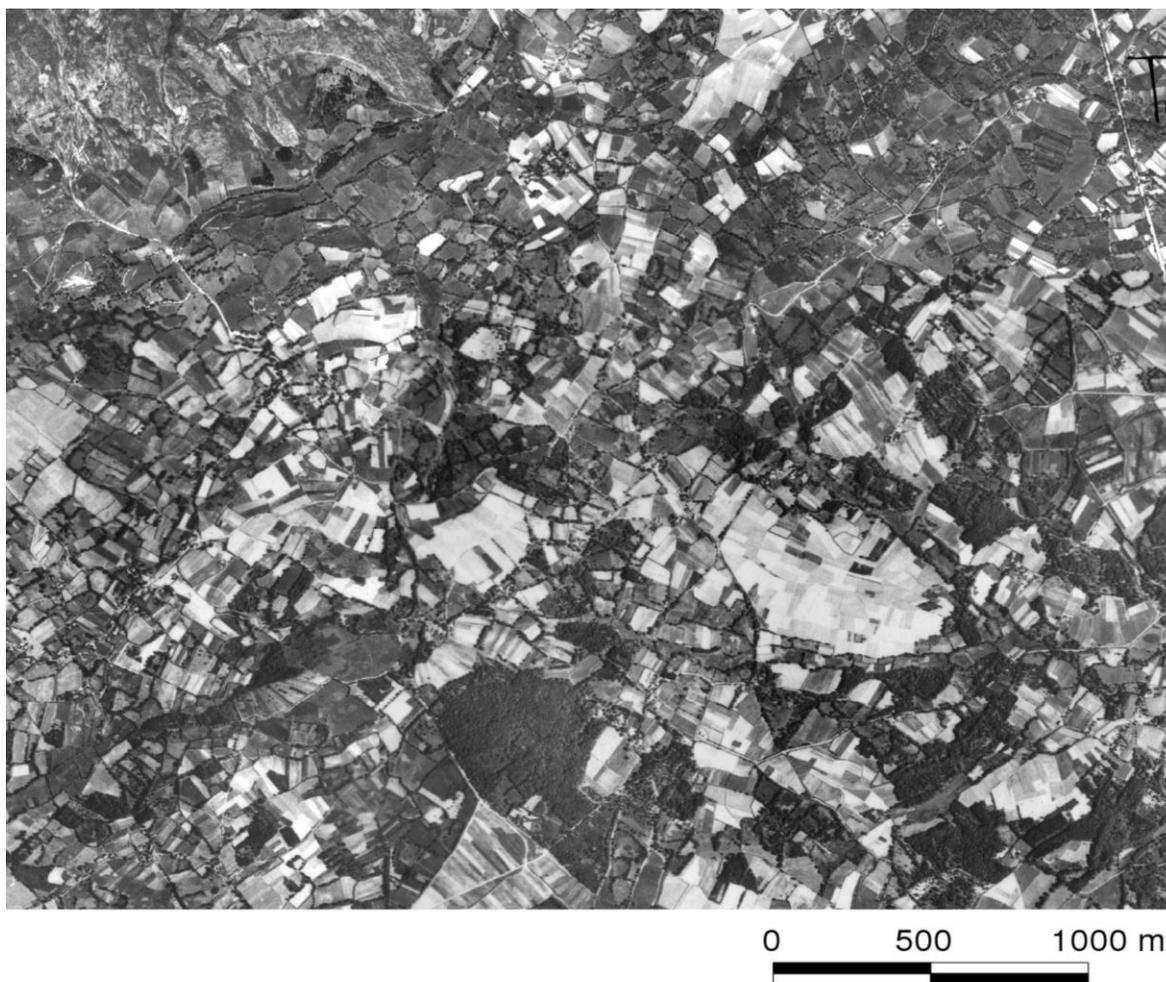
Fiabilidad global: 59,5%. Kappa de Cohen: 0,471.

**Tabla 5. Matriz de confusión: FNEA con información textual**

Clasificación	Referencia				Fiab. usuario	Fiab. productor
	Arable	Prados	Matorral	Arbolado		
Arable	43	2	0	1	93,5%	65,2%
Prados	4	18	1	1	75,0%	35,3%
Matorral	17	19	17	9	27,4%	53,1%
Arbolado	2	12	14	40	58,8%	78,4%

Fiabilidad global: 59,0%. Kappa de Cohen: 0,456.

## FIGURAS



**Figura 1. Área de trabajo en la fotografía original.**

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157

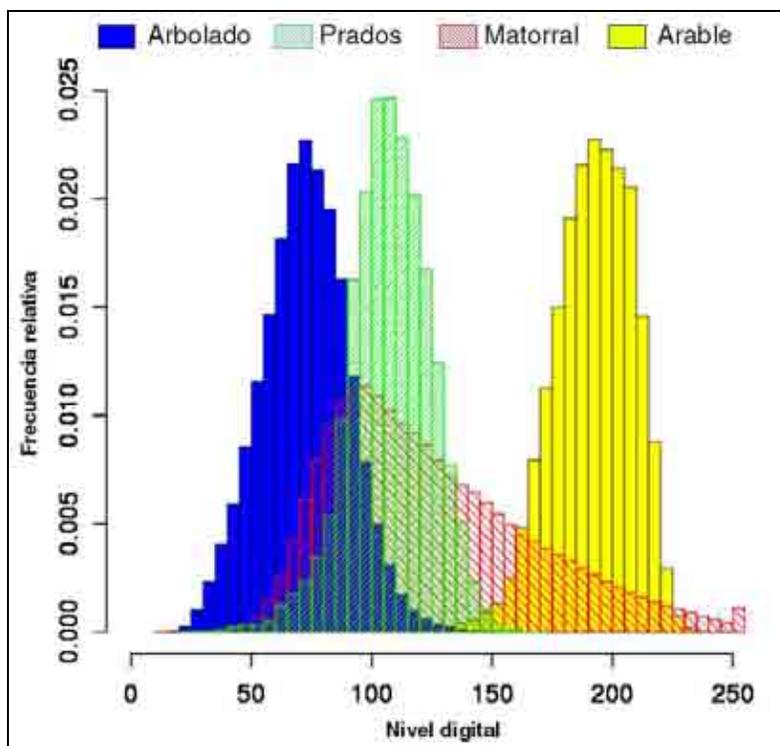
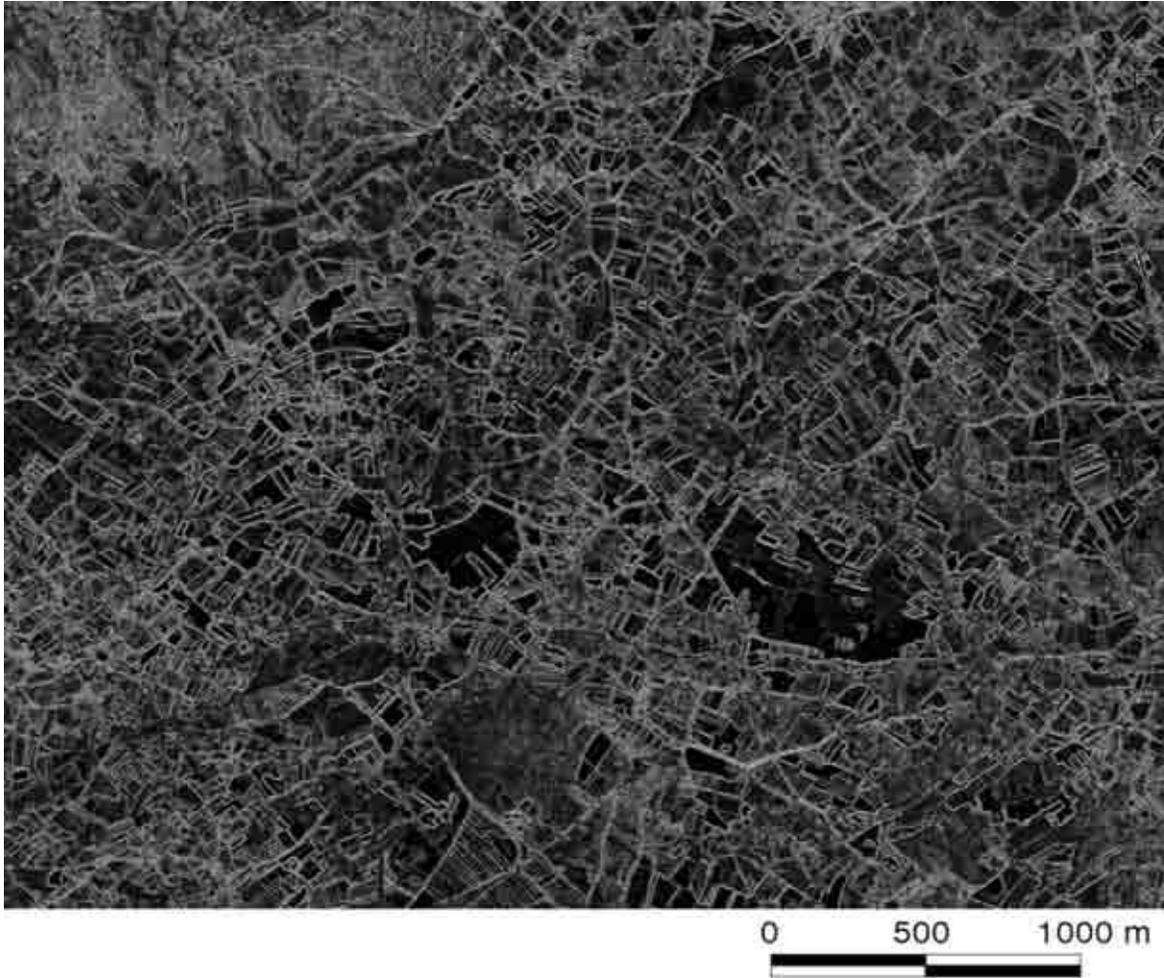


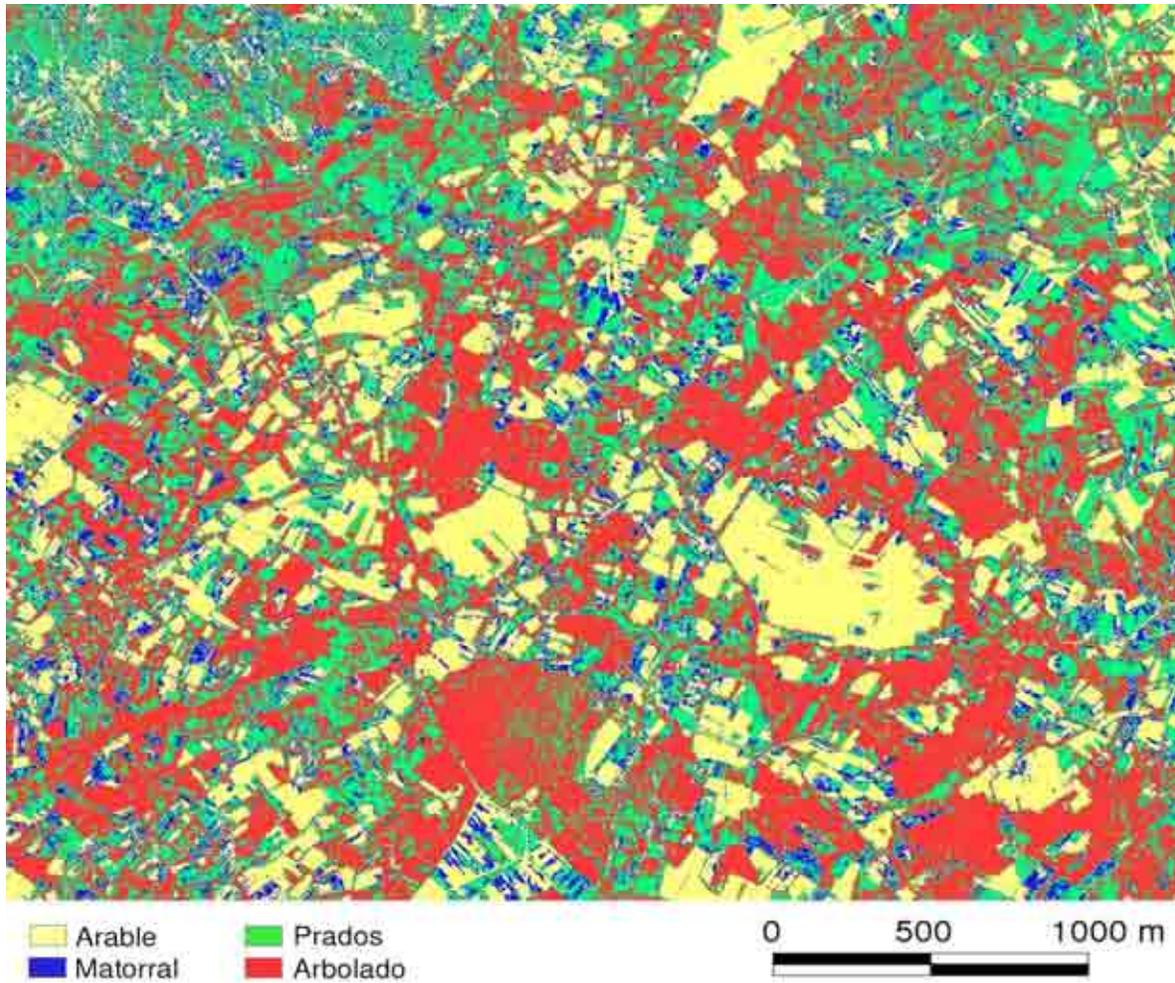
Figura 2. Histogramas de niveles digitales de las diferentes cubiertas.

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157



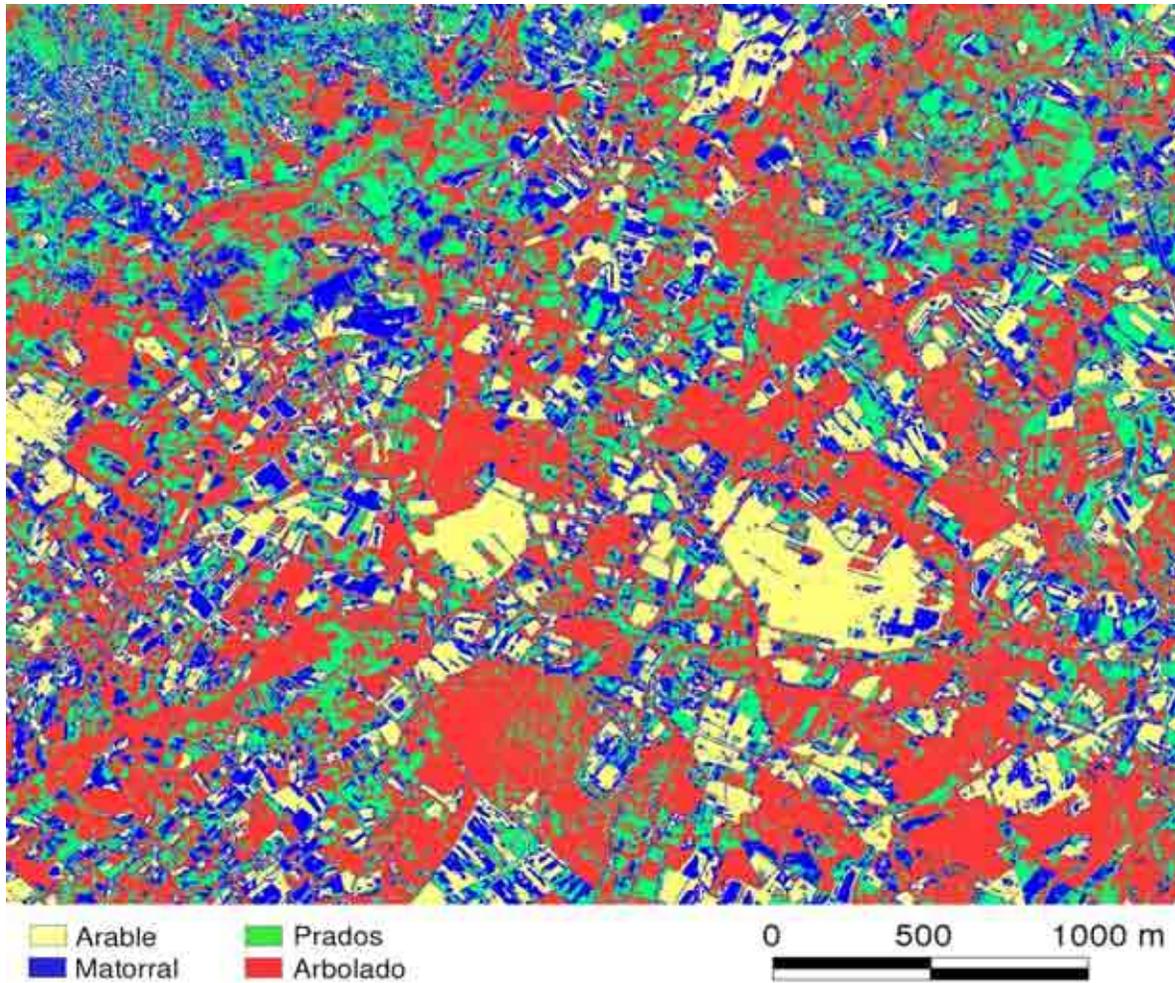
**Figura 3. Varianza calculada sobre la imagen original.**

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157



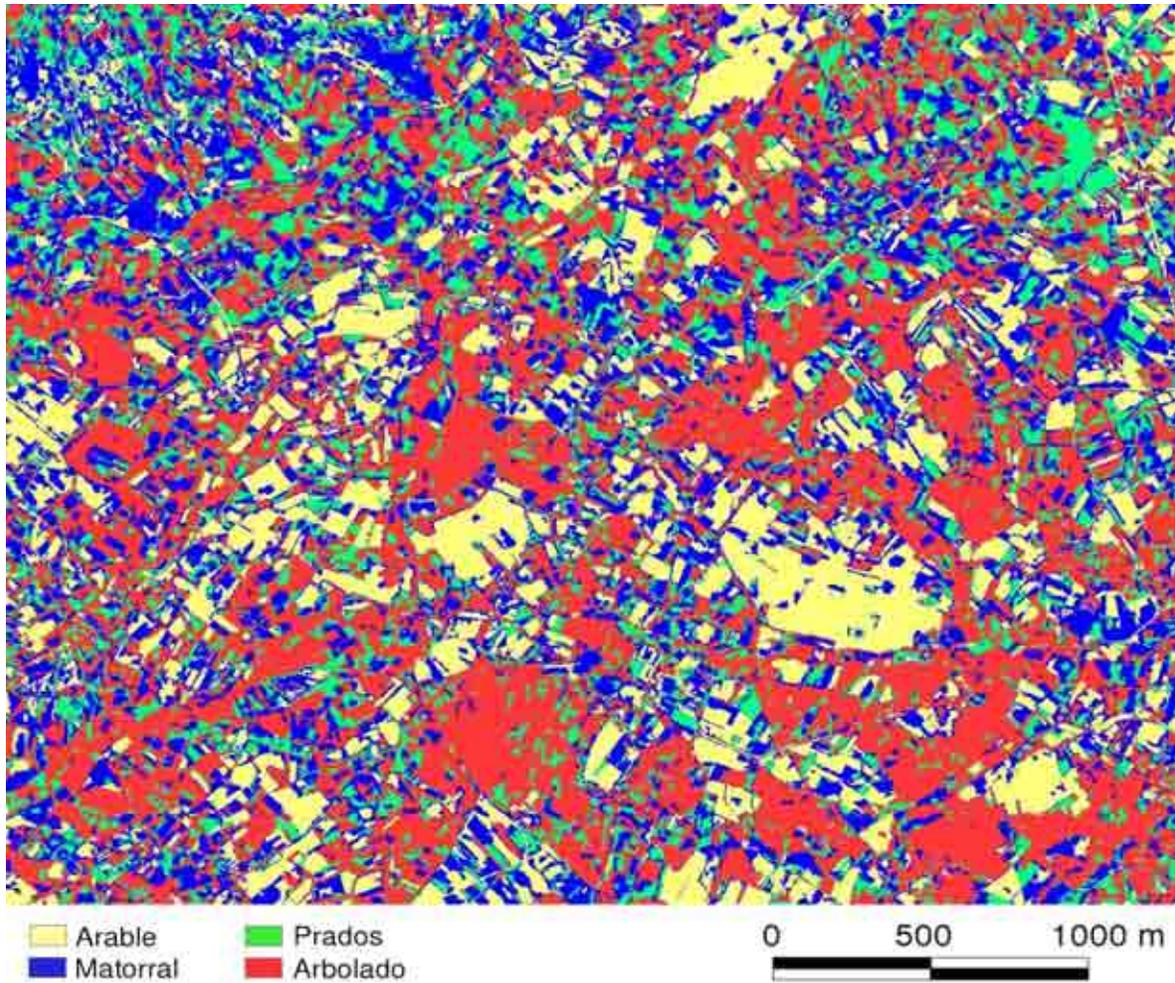
**Figura 4. Clasificación por umbrales.**

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157



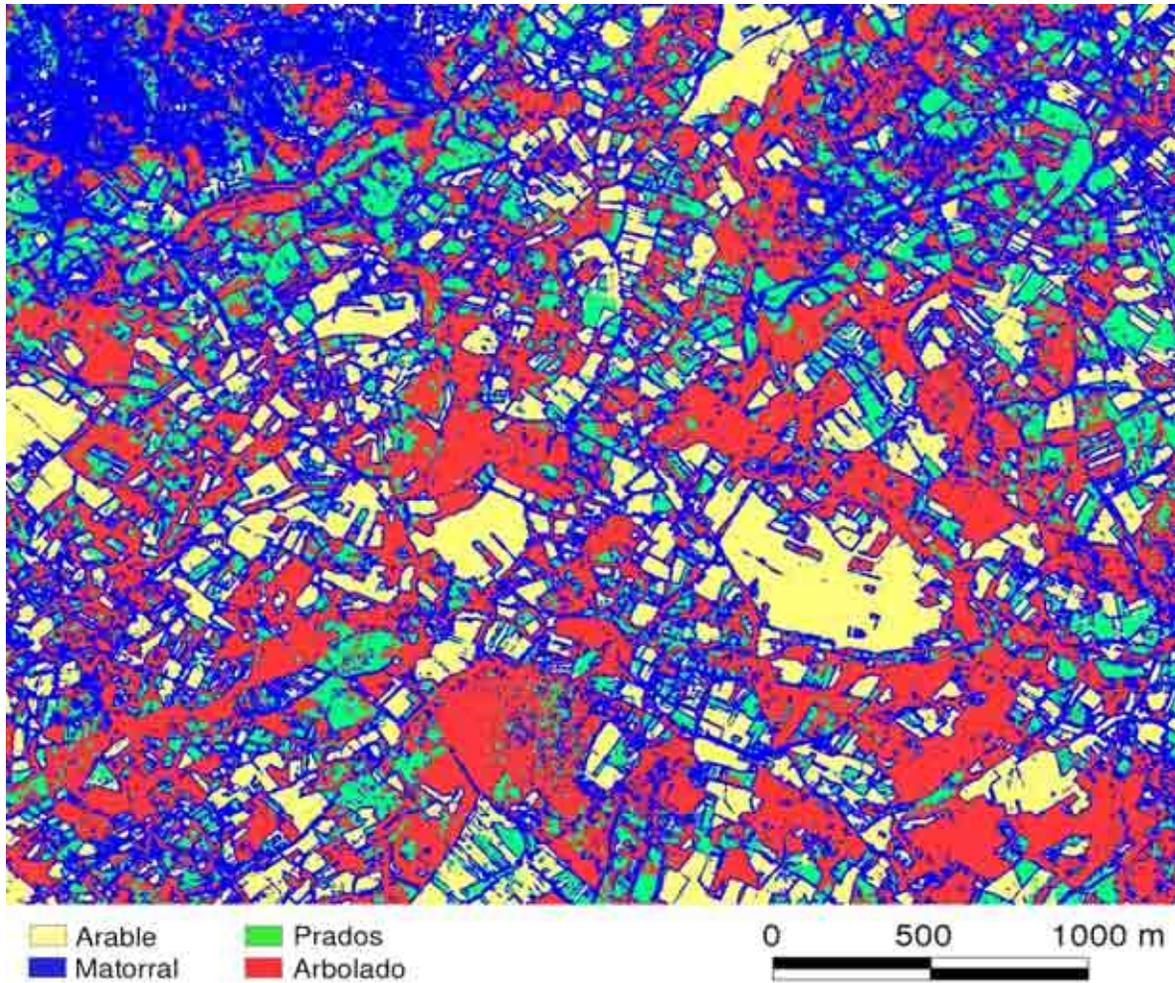
**Figura 5. Clasificación SMAP sin información textual.**

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157



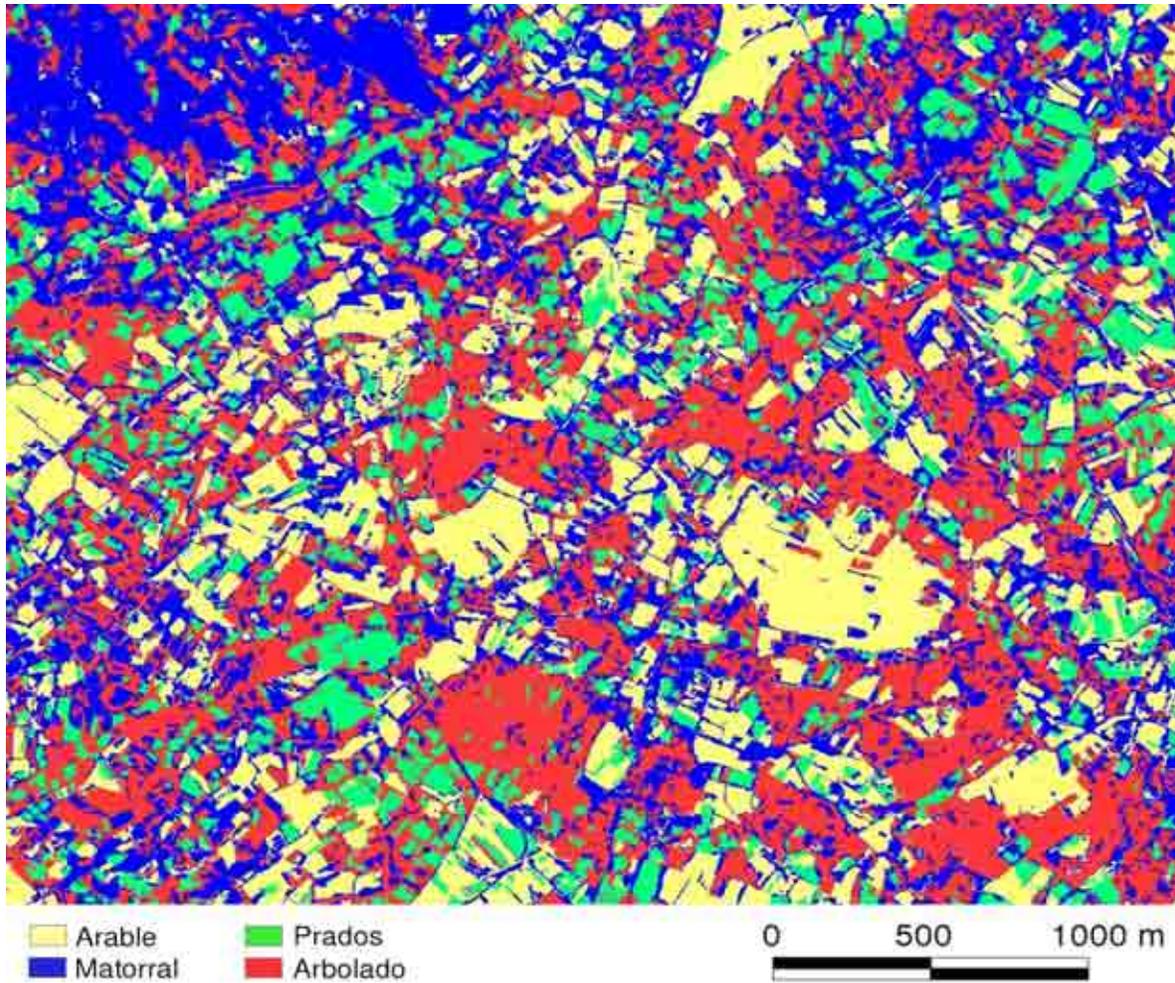
**Figura 6. Clasificación FNEA sin información textural.**

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157



**Figura 7. Clasificación SMAP con información textural.**

Corbelle Rico, E. y Crecente Maseda, R. (2009): "Métodos para la clasificación automática de fotografías aéreas históricas en blanco y negro", *GeoFocus (Artículos)*, n° 9, p. 270-289. ISSN: 1578-5157



**Figura 8. Clasificación FNEA con información textural.**