

COMPARACIÓN DE MÉTODOS DE CLASIFICACIÓN DE IMÁGENES DE SATÉLITE EN LA CUENCA DEL RÍO ARGOS (REGIÓN DE MURCIA)

Nicolás del Toro Espín
Francisco Gomariz-Castillo¹
Fulgencio Cánovas-García²
Francisco Alonso-Sarriá²

¹ Departamento de Ciencias del Mar y Biología aplicada. Universidad de Alicante. Instituto Euromediterráneo del Agua (Campus de la Merced Universidad de Murcia)

² Departamento de Geografía de la Universidad de Murcia.
Instituto del Agua y del Medio Ambiente de la Universidad de Murcia.
francisco.gomariz@ua.es, fulgencio.canovas@um.es, alonsarp@um.es

RESUMEN

En este trabajo se utiliza un método de aprendizaje automático para clasificar imágenes de satélite: Random Forest y un método de clasificación contextual: SMAP. Los resultados se comparan con los obtenidos por el método de máxima verosimilitud. Por otra parte se estudia como la incorporación de información relativa a la textura pueden mejorar la clasificación. Además de utilizar los índices de validación habituales, se analiza la mejora respecto a un clasificador ingenuo: el método de mínima distancia, y se comparan las superficies de cada uso con las extraídas de Corine Land Cover.

Palabras clave: Teledetección, aprendizaje automático, clasificación, textura, contexto, usos del suelo.

ABSTRACT

The results obtained with a machine learning method to classify satellite imagery: Random Forest and a contextual classification method: SMAP are compared with those obtained using maximum likelihood. In addition, we study how the incorporation of textural

Fecha de recepción: marzo 2013.

Fecha de aceptación: diciembre 2013.

information can improve classification. To validate the results, the usual indices are used and the relative improvement with respect to a naive classifier (minimum distance) is measured. In addition, land use surfaces are compared with those obtained from Corine Land Cover maps.

Key words: Remote sensing, machine learning, classification, texture, context, land use.

I. INTRODUCCIÓN

La clasificación de imágenes es el objeto de gran cantidad de trabajos en teledetección. Rees (2005) la define como la rama de la teledetección en la que se toman decisiones en base a los datos que aparecen en la imagen. Habitualmente se distingue entre clasificación supervisada y no supervisada. La primera incluye cuatro fases:

1. Establecer el número de clases y caracterizarlas en función de sus valores de reflectividad. Para ello deben analizarse las características espectrales de una serie de casos cuya clase se conoce a priori y que, en teledetección, se denominan áreas de entrenamiento.
2. Calibrar un modelo de clasificación a partir de estas áreas de entrenamiento. En el apartado IV.2 se describen los modelos utilizados en este trabajo.
3. Validar el modelo de clasificación utilizando áreas de validación. Se trata de áreas obtenidas del mismo modo que las áreas de entrenamiento pero no utilizadas en la fase calibración.
4. Utilizar el modelo de clasificación generado para obtener un mapa de usos del suelo a partir de las diferentes capas de reflectividad.

Habitualmente, la caracterización de clases se hace a partir de los valores de reflectividad, aunque también puede tenerse en cuenta la información textural o contextual. Mientras que la primera hace referencia a las características de la vecindad del píxel, la segunda se refiere al contexto espacial en el que se encuentra la celdilla. Zhou y Robson (2001) afirman que la incorporación de variables texturales es necesaria para obtener una adecuada clasificación. Por su parte, Berberoglu et al. (2007) resaltan la importancia de este tipo de información, especialmente en paisajes mediterráneos debido a la gran variedad y fragmentación de los patrones espaciales. La clasificación contextual, por otra parte, suele utilizarse con la intención de minimizar la aparición en el mapa final de celdillas de usos diversos entremezcladas (Tso y Mather, 2009).

Entre los modelos de clasificación más utilizados en teledetección, destaca el de máxima verosimilitud o análisis discriminante (Chuvienco, 2006; Tso y Mather, 2009). Se trata de un método estadístico clásico que asume normalidad en los valores de reflectividad para todas las bandas y clases. Recientemente se ha puesto de manifiesto que estas técnicas estadísticas convencionales, a pesar de haber sido utilizadas con éxito en teledetección durante más de cuatro décadas, pueden no ser las más adecuadas (Richards y Jia, 1999). Sus limitaciones han planteado la necesidad de adoptar una nueva generación de herramientas y técnicas, que permiten extraer conocimiento útil a partir de la información disponible, englobadas bajo la denominación de minería de datos o aprendizaje automático. Witten y Frank (1999) definen

la minería de datos como el proceso de extraer conocimiento útil y comprensible, previamente desconocido, desde grandes cantidades de datos almacenados en distintos formatos. Su objetivo fundamental es encontrar modelos inteligibles a partir de los datos. Para que este proceso sea efectivo debería ser automático o semi-automático y el uso de los patrones descubiertos debería ayudar a tomar decisiones más seguras.

En cuanto a la validación del modelo de clasificación, el método más habitual es utilizar la matriz de confusión y dos índices extraídos de ella: el porcentaje de celdillas correctamente clasificadas y el índice kappa (Congalton y Green, 1999), si bien existen muchos más índices que han sido utilizados en la bibliografía (Foody, 2002; Liu et al., 2006). El índice kappa trata de eliminar el efecto que los píxeles correctamente clasificados por azar tienen sobre el porcentaje de píxeles correctamente clasificados, de manera que una clasificación aleatoria tendría, en principio, un índice kappa igual a cero. Una de las críticas, a nuestro juicio, más interesantes a este planteamiento es que realmente no habría que comparar con una clasificación al azar, sino con un método ingenuo que se utilizaría como clasificador de base (Pontius y Millones, 2011). Sería algo similar a lo que ocurre en un modelo de regresión lineal en el que la estimación obtenida se compara con la que se obtendría utilizando la media como estimador y no con una estimación al azar.

II. OBJETIVOS

El presente trabajo tiene como objetivo principal realizar una clasificación de usos del suelo de la cuenca del Argos a partir de imágenes del satélite Landsat TM siguiendo el siguiente esquema de clasificación:

1. Bosque
2. Matorral
3. Cultivo arbóreo de secano
4. Cultivo arbóreo de regadío
5. Cultivo herbáceo de secano
6. Cultivo herbáceo de regadío
7. Urbano
8. Agua
9. Suelo desnudo
10. Vid

Para ello se utilizarán tres métodos distintos de clasificación con el fin de descubrir cuál de ellos resulta más adecuado para la zona de estudio. Los objetivos específicos son los siguientes:

1. Comparar los resultados obtenidos mediante tres métodos diferentes de clasificación:
 - Máxima Verosimilitud, como clasificador convencional
 - SMAP, como clasificador contextual
 - Random Forest, como clasificador perteneciente al conjunto de técnicas de aprendizaje automático.

2. Comprobar la hipótesis de que la incorporación de variables de textura mejora la clasificación.
3. Utilizar la clasificación por mínima distancia como clasificador de base con el que comparar los resultados del resto de los métodos de clasificación. Los intervalos de confianza de kappa se utilizarán como criterio para determinar el grado de significación de las diferencias en el índice kappa de los distintos clasificadores.

El objetivo de este trabajo es ambicioso en comparación con la mayoría de los estudios de teledetección, ya que para llevarlo a cabo utilizaremos 10 clases distintas, cuando habitualmente se utilizan entre 3 y 7 (Liu et al., 2006). Esto sin duda añadirá un importante grado de dificultad. Sin embargo, se ha preferido utilizar un conjunto de clases más amplio para cumplir un último objetivo, que será comprobar que clases se clasifican mejor con cada uno de los métodos utilizando el criterio de los intervalos de confianza.


III. ÁREA DE ESTUDIO

Para que los resultados obtenidos sean representativos, y se pueda hacer una valoración de los distintos métodos de clasificación, así como de la hipótesis de la inclusión de variables de textura, se ha elegido una superficie de extensión y complejidad considerable, como es la cuenca del río Argos. En ella aparece una gran variedad de usos del suelo.

La cuenca del río Argos se localiza en el sureste de la Península Ibérica, y más concretamente en la comarca del Noroeste de la Región de Murcia. Tiene una superficie de 51.786 ha, y se encuentra localizada en la zona central de la cuenca del Río Segura, del que es afluente. El cauce principal de la cuenca: el río Argos, nace en las Sierras de Villafuerte y el Cerro de los Frailes, donde se alcanzan cotas en torno a los 1600 metros, y discurre paralelo al Benamor por el norte y al Quípar por el sur. El relieve es muy escarpado en cabecera para ser prácticamente llano en el resto del territorio (Cebrián Abellán, 2007). La cuenca está formada por materiales carbonatados que forman los principales relieves. Al pie de estos relieves aparecen depósitos cuaternarios (abanicos aluviales, glaciares, depósitos piedemonte y coluviones) por donde discurren los afluentes del río Argos. El cauce principal ha dejado al descubierto, por erosión de los sedimentos cuaternarios, los depósitos de arcillas abigarradas y yesos en facies Keuper situados bajo aquellos. Es frecuente encontrar procesos de erosión sobre estos materiales, estas son fácilmente identificables en los márgenes del cauce. El lecho del cauce está formado por arcillas, gravas y limos que dan lugar a suelos muy fértiles aprovechados para uso agrícola.

El clima de la cuenca se enmarca dentro de los pisos Mesomediterráneo, y Supramediterráneo. El primero representa casi la totalidad de la superficie, a excepción de las partes más altas, correspondientes a las Sierras de Mojantes, Gavilán, Villafuerte y Cerro de los Frailes, en donde el piso bioclimático es el Supramediterráneo. La diferencia de altitud se manifiesta en las condiciones climáticas, siendo la temperatura media de 12 °C en las zonas altas, mientras que se alcanzan valores en torno a los 16 °C, desde el núcleo urbano de Cehegín hasta la desembocadura de la cuenca. La precipitación oscila de forma importante desde las zonas altas de la cuenca donde se recogen más de 400 mm de media al año, hasta las zonas más bajas donde pueden recogerse incluso menos de 200 mm (Cebrián Abellán, 2007).

Figura 1
LOCALIZACIÓN DEL ÁREA DE ESTUDIO



El Argos es uno de los pocos afluentes no efímeros del río Segura. Su caudal es casi permanente con la excepción de periodos de importantes sequías. El origen del Argos lo encontramos en las ramblas de La Higuera y de las Buitreras, que recogen la escorrentía de las sierras de La Muela, Moreras, Villafuerte y Solana de la Terraza, y 200 metros aguas abajo se le une las procedentes de la sierra del Gavilán, unos 2 km antes de llegar a Valentín se represa, para llegar al municipio de Calasparra donde desemboca en el río Segura.

Pueden distinguirse tres grandes usos del suelo dentro de la cuenca, el principal es el uso natural que representa el 51,4 % de la superficie total. Está formado por formaciones boscosas, arbustivas y subarbustivas. El segundo es el uso agrícola, con un 42,3 %, y podemos encontrarlo sobre todo en el valle del río y en los conos de deyección y glaciares cuaternarios. Sobre estas geoformas se desarrollan suelos muy productivos ricos en limos, arcillas y gravas. La proporción de secano y regadío es similar, siendo los frutales el principal cultivo en regadío y los cereales y almendros en secano. Por último, las zonas urbanas ocupan sólo un 2,2% del territorio, siendo Caravaca, Cehegín y Calasparra los núcleos más importantes.

Teniendo en cuenta esta variabilidad de usos de suelo en el área de estudio, la cuenca del Río Argos resulta adecuada para comparar los resultados de los cuatro métodos de clasificación que se van a analizar en este trabajo. Sin embargo, debido a que existen cultivos tanto de secano como de regadío casi por partes iguales, es posible que los resultados dependiendo del método de clasificación puedan confundir diversos píxeles, clasificando el regadío en secano y viceversa. Debido además a la resolución de las imágenes del satélite Landsat TM, los cultivos de regadío (herbáceo y arbóreo) pueden confundirse entre sí.

En definitiva, podemos imaginar que en el proceso de clasificación de los diferentes usos del suelo, tendremos dos usos relativamente sencillos de clasificar, como son el uso forestal y el urbano, aunque este último podría confundirse con el suelo desnudo. Siendo los cultivos tanto de secano como de regadío los que mayores dificultades presenten.

IV. MATERIAL Y MÉTODOS

IV.1. Datos de partida

Los datos usados en el presente trabajo corresponden a una imagen de landsat de 8 de agosto del año 2000, incluida en la colección multitemporal de imágenes correspondientes al ámbito de la Demarcación Hidrográfica del Segura (DHS) desde 1976 hasta 2007 creados en Instituto del Agua y Medio Ambiente, Universidad de Murcia (Alonso Sarría, et al., 2010). Estas imágenes fueron georreferenciadas, y corregidas para eliminar los efectos de atmósfera e iluminación, siguiendo los métodos de Chávez (1988) y Teillet et al. (1982), respectivamente. Una explicación más detallada de todo el proceso aparece en Alonso Sarría et al. (2010).

Puesto que el objetivo de este trabajo es clasificar una imagen adquirida hace más de una década, las áreas de entrenamiento y validación deben obtenerse a partir de análisis multitemporales de fotografía aérea y mapas de usos del suelo. Para ello se utilizaron las capas de áreas de entrenamiento y validación para la cuenca del Segura presentadas en Alonso Sarría, et al. (2010). En la zona de estudio de este trabajo, dichas capas incluyen 111 áreas de entrenamiento y 56 áreas de validación.

Otro de los objetivos es verificar si la incorporación de información textural mejora la clasificación de la imagen. Habitualmente se han empleado tres aproximaciones para la obtención de información textural (Benediktsson y Sveinsson, 1997):

1. Estadísticos clásicos (desviación típica).
2. Índices de textura derivados de la matriz de concurrencias.
3. Función semivariograma.

En general, se considera a la primera opción la más limitada (Berberoglu y otros, 2007), mientras que la tercera es la más utilizada en ciencias de la Tierra. El uso de semivariogramas en teledetección se ha hecho siguiendo dos aproximaciones (Atkinson y Lewis, 2000):

1. Cálculo del semivariograma experimental para distancias relativamente cortas utilizando dichos valores como nuevas bandas.
2. Obtención de una capa de los parámetros de un modelo teórico de semivariograma ajustado a partir de los respectivos semivariogramas teóricos para cada uno de los píxeles.

Evidentemente la segunda opción es mucho más compleja, por lo que se ha utilizado una versión simplificada de la primera (Alonso Sarría et al., 2010). Se obtuvieron dos capas de información textural utilizando la función semivariograma:

$$g = \frac{\sum_{i=1}^4 (b - b_i)^2}{8}$$

Donde b hace referencia al valor de la celdilla analizada y b_i al valor en cada una de las cuatro celdillas adyacentes (norte, sur, este y oeste).

Esta función se aplicó a dos bandas derivadas de las originales y que resumen gran parte de la información útil que contiene la imagen:

- Primer componente obtenido de un Análisis de Componentes Principales (ACP) sobre las capas de reflectividad. Este primer componente suele relacionarse con una reflectividad media ponderada de la imagen. De hecho los pesos que permiten calcular los componentes a partir de las capas de reflectividad tienen todos el mismo signo y similares valores absolutos.
- Índice Normalizado de Vegetación (NDVI) utilizando la formulación clásica (Chuvieco, 2006):

$$NDVI = \frac{b_4 - b_3}{b_4 + b_3}$$

IV.2. Métodos de clasificación

IV.2.1. Mínima distancia

Este método de clasificación es uno de los más antiguos y hoy se puede considerar en desuso salvo para propósitos docentes, sin embargo se ha incluido como «clasificador ingenuo» con el que comparar el resto de los métodos de clasificación. Consiste en asignar cada celdilla a la clase respecto a cuyo vector de medias está más próxima en el espacio de variables. Como medida de distancia se utilizó la distancia euclidiana (Chuvieco, 2006).

IV.2.2. Máxima verosimilitud

El método de clasificación por Máxima Verosimilitud (ML) o máxima probabilidad (Chuvieco, 2006; Tso y Mather, 2009) parte del supuesto de que los valores de reflectividad en cada una de las clases siguen una distribución de probabilidad normal multivariante. Se utiliza entonces el vector de medias y la matriz de varianzas-covarianzas para estimar la probabilidad de que un píxel dado pertenezca a cada una de las clases. El píxel se asignará finalmente a la clase cuya probabilidad de pertenencia sea mayor.

Una vez terminada la asignación de píxeles a las distintas clases, se pueden establecer unos umbrales de probabilidad para cada categoría, rechazando los píxeles con una probabilidad muy baja, evitando de esta manera que se clasifiquen píxeles en clases en las que realmente no pertenecen. De esta manera tendremos un número de píxeles sin clasificar, y en el caso de ser muy grande se debe retornar la fase de entrenamiento para deducir así nuevas categorías o perfeccionar las ya existentes. En todo caso el valor de probabilidad máxima puede utilizarse como indicador de la certeza en la clasificación.

Frecuentemente se utiliza un enfoque bayesiano y se incluye también la probabilidad a priori de que un píxel pertenezca a una clase determinada, debido a que algunas categorías cuentan con una superficie mayor, y por lo tanto la probabilidad de que una celdilla pertenezca a ella es, a priori, mayor.

El método de Máxima Verosimilitud es el más utilizado en teledetección; sin embargo, el supuesto básico de normalidad no siempre se cumple, por lo que debería verificarse antes de aplicarlo. No obstante, algunos autores han planteado que, aun en el caso de que las bandas de entrada no cumplan este criterio, los resultados siguen siendo bastantes consistentes (Swain y Davis, 1978).

IV.2.3. SMAP

El algoritmo Sequential Maximun a Posteriori (SMAP) es un método de clasificación contextual que realiza una clasificación de los píxeles por regiones y no de manera individual, en este sentido se puede considerar también un método de segmentación. Se parte del supuesto de que las celdillas que se encuentran cercanas en una imagen pertenecen a la misma clase, por lo que trabaja fraccionando la imagen en varias resoluciones, de esta manera usa la resolución de fragmentación más gruesa para obtener una función de densidad a priori para la más fina a partir de la que, utilizando un enfoque bayesiano, obtener una distribución a posteriori (Bouman y Shapiro, 1994; Cheng y Bouman, 2001). El resultado final es un mapa de usos del suelo con polígonos más grandes y homogéneos.

Para este método, el único parámetro que debe definirse es el tamaño de la ventana o submatriz a procesar a la vez. El objetivo de este parámetro es controlar la carga en memoria del programa sin embargo puede influir, aunque levemente, en los resultados. Dado que los parámetros de suavizado del algoritmo de segmentación se estiman para cada ventana por separado, se aconseja el uso de una submatriz pequeña.

Un enfoque similar a este es el uso de los Random Markov Fields (MFR) (Tso y Mather, 2009). Tales algoritmos son, sin embargo computacionalmente intensivos lo que limita su utilidad. El algoritmo SMAP resulta así más eficiente (Bouman y Shapiro, 1994).

Diversos autores (McCauley y Engel, 1995; Ehsani, 2011) han comparado el algoritmo SMAP con la máxima verosimilitud, encontrando que SMAP produce mejores resultados.

IV.2.4. Random Forest

Random Forest (Breiman, 2001) es un meta-clasificador que utiliza árboles de decisión como clasificadores base, donde cada clasificador contribuye con un voto para la asignación de la clase más frecuente. Por ello, primero se explicará como funciona un árbol de decisión para, después, explicar el funcionamiento conjunto de varios árboles en Random Forest.

Un árbol de decisión se construye mediante sucesivas particiones binarias del conjunto de datos de entrenamiento en subconjuntos (nodos) de homogeneidad creciente. La homogeneidad se mide con el índice de Gini (G) (Breiman et al., 1984) que se reduce al mínimo cuando todas las observaciones pertenecen a la misma clase. En cada paso, el nodo con mayor valor de G se divide en función de que los valores de sus celdillas para una determinada variable superen o no un determinado umbral. Dicho umbral y variable

se seleccionan para minimizar el valor de G en los nodos resultantes. El proceso continúa hasta que ninguna subdivisión puede reducir más el índice de Gini (Cutler et al., 2007).

El resultado final debe ser un árbol de clasificación cuyos nodos finales se etiquetan en función de la clase predominante siendo el resto de los casos errores de clasificación. A partir de estos errores es posible podar el árbol para darle mayor capacidad de generalización. Un árbol así generado puede utilizarse después para clasificar nuevos casos.

El principal problema de la clasificación con un único árbol es su alta sensibilidad a los datos de entrada, por lo que se han propuesto alternativas basadas en conjuntos de árboles como *boosting*, *bagging* o *Random Forest* (Breiman, 1994). Este último consiste en utilizar un gran conjunto de árboles (500-2000) que se entrenan con diferentes subconjuntos del conjunto inicial de entrenamiento. Estos subconjuntos se obtienen mediante *bootstrapping*, de este modo cada árbol se entrena con aproximadamente dos tercios de los casos originales y el tercio restante (denominado *out of bag*) se reserva para validación. Además, cada árbol se entrena con un subconjunto aleatorio de las variables predictoras. Esta modificación, algo antiintuitiva, añade aleatoriedad y disminuye la correlación entre árboles. Esta falta de correlación es una propiedad deseable que da sentido a la última fase del proceso, consistente en un sistema de votación por el que cada nuevo caso se asigna a la clase estimada por un mayor número de árboles.

Este algoritmo tan solo necesita dos parámetros, el parámetro m (número de variables utilizadas al azar para cada división o número de variables predictivas) y el parámetro k (número de árboles de clasificación). Para este trabajo se ha utilizado la versión implementada en R (Liaw y Wiener, 2002), que contiene funciones para estimar de forma automática el valor óptimo del parámetro m . En cuanto al parámetro k , por defecto se establece el valor 500 (Liaw y Wiener, 2002), tal como se señala en Cánovas García (2012) valores superiores no parecen tener como resultado un aumento importante en la exactitud de la clasificación.

Random Forest produce muy buenos resultados en comparación con otros sistemas de clasificación basados o no en árboles de decisión (Breiman, 2001; Liaw y Wiener, 2002) incluso cuando hay más variables que observaciones o cuando la mayoría de las variables son ruido. Especialmente interesante es el hecho de que no sobreajusta el modelo (Ghimire et al., 2010) obteniéndose una gran capacidad de generalización (Breiman, 2001; Pal, 2005; Prasad et al., 2006). Proporciona además un ranking de importancia de las variables que permite determinar cual es la que más ha pesado en todo el proceso de decisión. Otras ventajas a destacar son (Urrea Galés, 2009):

- Funciona de forma eficiente en grandes bases de datos.
- Calcula una estimación insesgada interna del error de generalización (OOB) a partir de los datos de entrenamiento.
- Calcula proximidades entre pares de casos que se pueden utilizar para identificar valores atípicos.

IV.3. Validación

La validación de las clasificaciones se ha llevado a cabo construyendo las correspondientes matrices de confusión y calculando los porcentajes de píxeles correctamente clasificados

y los valores del índice kappa, así como sus intervalos de confianza para un nivel de probabilidad del 95 %. También se han calculado los errores de omisión y comisión para cada una de las clases y los kappa de usuario y productor para cada clase junto con sus correspondientes intervalos de confianza.

Además de los índices de validación habituales se ha utilizado el mapa de usos del suelo del proyecto Corine Land Cover para calcular la discrepancia en cuanto al área ocupada por cada uso. La leyenda de este mapa es diferentes al esquema de clasificación realizado en este trabajo y la recogida de datos es algo anterior a la fecha de toma de la imagen por lo que cabe esperar ciertas discrepancias:

En realidad, la semántica de los diferentes usos del suelo del mapa Corine LandCover no es la misma que la del esquema de clasificación utilizado en este trabajo. La correspondencia entre ambas se realizó analizando ambas leyendas y, en caso de duda, buscando la máxima correspondencia espacial entre ambos conjuntos de clases. Las zonas urbanas, mineras, infraestructuras de comunicación y áreas recreativas se asimilan a la clase urbano; el matorral boscoso se asimila a bosque y la vid que aparece en las clasificaciones se asimila a herbáceo de secano; finalmente, los prados y praderas se asimilan a zonas de matorral.

En resumen, la asimilación de ambas leyendas se llevo a cabo a partir de las siguientes reglas de reclasificación para el mapa del proyecto Corine:

- 00000-15000: Zonas urbanas
- 21100: Herbáceos de secano
- 21200-21999: Herbáceos de regadío
- 22200-22299: Arbóreo de regadío
- 23000-23999: Matorral
- 24000-25000: Arbóreo de secano
- 31000-31300: Bosques
- 32000-32399: Matorral
- 32400-32999: Bosque
- 33000-34000: Suelo desnudo
- 50000-53000: Agua

IV.4. Recursos informáticos utilizados

El trabajo se ha llevado a cabo en un entorno Linux utilizando GRASS (Neteler y Mitasova, 2008) como programa para el almacenamiento y gestión de imágenes de satélite. Se trata de un SIG de código abierto publicado bajo licencia GPL. En el se hizo todo el tratamiento previo de corrección, calculo de reflectividad y cálculo de variables de textura. Así mismo la clasificación por máxima verosimilitud y SMAP se llevaron a cabo utilizando los módulos del programa. La clasificación de mínima distancia se realizó utilizando un módulo de GRASS programado ex profeso por los autores.

La clasificación utilizando Random Forest se llevó a cabo utilizando el programa de análisis de datos R creado por Ihaka y Gentleman (1996) utilizando los paquetes *sprgrass6* (Bivand, 2007) para leer desde R capas de GRASS y *randomForest* (Liaw y Wiener, 2002) que implementa este algoritmo.

V. RESULTADOS Y DISCUSIÓN

El Cuadro 1 presenta los porcentajes de acierto, valores del índice kappa y los correspondientes límites del intervalo de confianza para una probabilidad del 95 %. Estos intervalos de confianza deben interpretarse como que la probabilidad de que el valor del parámetro para el conjunto de la imagen se encuentre entre el límite inferior y el superior es de un 95%. El Cuadro 2 muestra los errores de omisión y comisión de los diferentes modelos, en este Cuadro la numeración de los usos del suelo corresponde con la que aparece en el apartado de objetivos, así como los kappa de usuario y productor. Los Cuadros 3 a 5, finalmente, muestran las matrices de confusión de los modelos de clasificación que obtuvieron mejores resultados (SMAP y Random Forest con y sin la inclusión de variables de textura).

Cuadro 1
 ÍNDICE KAPPA (K), PORCENTAJE DE ACIERTO (P) E INTERVALOS DE CONFIANZA (IC INF E IC SUP)
 PARA UN NIVEL DE SIGNIFICACIÓN DE 0,05

Método	MD	MV	SMAP	RF	SMAP-T	RF-T
K	0,302	0,656	0,747	0,728	0,786	0,741
IC inf	0,295	0,65	0,741	0,722	0,781	0,735
IC sup	0,308	0,663	0,752	0,734	0,792	0,747
P	42,16	72,93	80,2	79,09	83,39	80,18
IC inf	41,57	72,41	79,75	78,61	82,95	79,71
IC sup	42,76	73,46	80,69	79,57	83,83	80,65

Los métodos que, de forma global, obtienen mejores resultados (Cuadro 1) son Random Forest (P=79,1) y SMAP (P=80,2); especialmente este último. Ambos métodos mejoran si se introducen variables de textura, sobre todo SMAP (P=83,4.), si bien la mejora que se observa no es muy importante. El método de máxima verosimilitud da unos resultados algo inferiores (P=72,9). Asumiendo que la ausencia de intersección entre sus intervalos de confianza para un nivel de significación de 0,05 indicaría que los estadísticos de exactitud de dos métodos son significativamente diferentes, puede afirmarse que el método que mejores resultados obtiene es SMAP incluyendo variables de textura, seguido de SMAP sin variables de textura y Random Forest con variables de textura (cuyos intervalos de confianza se yuxtaponen) y finalmente Random Forest sin variables de textura y Máxima Verosimilitud.

Respecto a los índices kappa, siguiendo el criterio de Landis y Koch (1977) para su interpretación, puede considerarse que la concordancia del clasificador de mínima distancia es baja y todas las demás buenas, aunque en el caso de SMAP con variables de textura se aproxima al umbral de la concordancia muy buena (kappa>0,8).

En cuanto a la mejora respecto al método de mínima distancia, los resultados superan en todos los casos el 50% de mejora, con una amplia separación entre los respectivos intervalos de confianza. Destaca de nuevo SMAP con la inclusión de variables de textura que casi dobla el porcentaje de acierto del método de mínima distancia.

Cuadro 2

ERRORES DE OMISIÓN Y COMISIÓN DE LAS DISTINTAS CLASIFICACIONES EFECTUADAS. EO: ERROR DE OMISIÓN, EC: ERROR DE COMISIÓN, MD: MÍNIMA DISTANCIA, MV: MÁXIMA VEROSIMILITUD, RF: RANDOM FOREST, SM: SMAP, T: CLASIFICACIÓN INCLUYENDO VARIABLES TEXTURALES. LA CORRESPONDENCIA ENTRE IDENTIFICADORES Y USOS ES LA SIGUIENTE: 1: BOSQUE, 2: MATORRAL, 3: CULTIVO ARBÓREO DE SECANO, 4: CULTIVO ARBÓREO DE REGADÍO, 5: CULTIVO HERBÁCEO DE SECANO, 6: CULTIVO HERBÁCEO DE REGADÍO, 7: URBANO, 8: AGUA, 9: SUELO DESNUDO Y 10: VID

	1	2	3	4	5	6	7	8	9	10
EC MD	43.7%	19.7%	85.9%	29.8%	36.2%	99.9%	91.9%	95.5%	29.1%	96.4%
EO MD	40.1%	60.1%	90.9%	79.1%	51.8%	99.7%	68.2%	0.7%	52.8%	84.1%
Kuser MD	0.3762	0.6871	0.0554	0.6921	0.5733	-0.010	0.0551	0.0398	0.6933	0.0224
Kuser i MD	0.3636	0.6689	0.0372	0.6343	0.5541	-0.013	0.0458	0.0331	0.6621	0.0137
Kuser s MD	0.3888	0.7053	0.0736	0.75	0.5925	-0.008	0.0645	0.0465	0.7245	0.0311
Kprod MD	0.4183	0.2461	0.0345	0.2010	0.4157	-0.039	0.2373	0.0915	0.4538	0.1038
Kprod i MD	0.4047	0.2369	0.0231	0.1743	0.3997	-0.046	0.1999	0.975	0.4268	0.0646
Kprod s MD	0.432	0.2554	0.0459	0.2278	0.4316	-0.032	0.2747	1.0081	0.4808	0.143
EC ML	9.5 %	9.5 %	33.5%	43.9%	30.9%	98.0%	76.6%	60.6%	32.7%	79.8%
EO ML	8.8%	22.7%	67.6%	19.7%	41.5%	89.0%	59.0%	16.5%	15.6%	58.9%
Kuser ML	0.8647	0.8560	0.6318	0.5465	0.6373	0.0089	0.2132	0.3907	0.6561	0.1914
Kuser i ML	0.856	0.8466	0.6028	0.5184	0.6199	0.0024	0.1901	0.3337	0.6329	0.163
Kuser s ML	0.8734	0.8655	0.6608	0.5746	0.6547	0.0153	0.2364	0.4476	0.6793	0.2198
Kprod ML	0.8753	0.6811	0.2934	0.7938	0.5256	0.0517	0.3814	0.8329	0.8342	0.3924
Kprod i ML	0.8668	0.6702	0.2752	0.7661	0.5094	0.0145	0.3443	0.7691	0.8136	0.3416
Kprod s ML	0.8838	0.6919	0.3116	0.8215	0.5419	0.0889	0.4185	0.8966	0.8548	0.4433
EC SM	2.45%	5.5%	21.2%	32.4%	17.4%	98.5%	64.9%	33.8%	15.7%	63.1%
EO SM	1.8%	10.4%	50.7%	33.8%	43.2%	87.4%	56 %	35.3%	14.3%	44.1%
Kuser SM	0.9653	0.9162	0.7676	0.6658	0.7958	0.0042	0.3333	0.6599	0.8345	0.3602
Kuser i SM	0.9606	0.9092	0.7454	0.6334	0.7795	0	0.302	0.5783	0.8142	0.3203
Kuser s SM	0.97	0.9233	0.7898	0.6981	0.812	0.0087	0.3645	0.7415	0.8547	0.4
Kprod SM	0.9748	0.8470	0.4635	0.6514	0.5195	0.0378	0.4213	0.6449	0.8497	0.5499
Kprod i SM	0.9707	0.8383	0.4435	0.6191	0.5036	-0.003	0.3844	0.5634	0.83	0.4987
Kprod s SM	0.9788	0.8558	0.4835	0.6837	0.5353	0.0787	0.4583	0.7264	0.8693	0.6012
EC RF	7.00%	11.4%	45.2%	34.6%	19.1%	97.4%	54.3%	16.4%	10.8%	41.4%
EO RF	3.5%	10.6%	26 %	35.8%	50.9%	88.4%	61.5%	13 %	41.1%	60.5%
Kuser RF	0.9008	0.8278	0.5040	0.6433	0.7757	0.0153	0.4425	0.8349	0.8873	0.5800
Kuser i RF	0.8933	0.8185	0.4864	0.6105	0.7578	0.007	0.4023	0.7733	0.8658	0.5184
Kuser s RF	0.9084	0.837	0.5217	0.6761	0.7936	0.0237	0.4828	0.8966	0.9087	0.6416
Kprod RF	0.9499	0.8394	0.7045	0.6309	0.4411	0.0707	0.3709	0.8791	0.5749	0.3896
Kprod i RF	0.9442	0.8303	0.6852	0.5982	0.4255	0.0331	0.3351	0.8235	0.5481	0.3399
Kprod s RF	0.9556	0.8485	0.7238	0.6637	0.4567	0.1084	0.4067	0.9346	0.6017	0.4394
EC SM-T	1.05%	6.13%	19.6%	32.5%	14.8%	99.6%	65.8%	42 %	15.4%	49.4%
EO SM-T	4.02%	8.36%	38.9%	14.7%	33.5%	98 %	56 %	7.5%	14.8%	56.4%
Kuser SM-T	0.9850	0.9076	0.7844	0.6649	0.8256	-0.007	0.3243	0.5782	0.8382	0.4995
Kuser i SM-T	0.9818	0.9003	0.7653	0.6364	0.8113	-0.01	0.2936	0.5116	0.8181	0.4443
Kuser s SM-T	0.9883	0.9149	0.8035	0.6933	0.8399	-0.004	0.355	0.6447	0.8584	0.5547
Kprod SM-T	0.9437	0.8754	0.6132	0.8471	0.6212	-0.044	0.4208	0.9242	0.8442	0.4289
Kprod i SM-T	0.9378	0.8673	0.5933	0.8226	0.6056	-0.061	0.3838	0.8791	0.8243	0.3783
Kprod s SM-T	0.9496	0.8835	0.633	0.8717	0.6368	-0.027	0.4578	0.9694	0.8642	0.4795
EC RF-T	4.92%	11.2%	47.6%	35.6%	19.1%	98.9%	49.7%	9.1%	6.9%	35.3%
EO RF-T	2.78%	7.7%	25.6%	36.8%	51.3%	95.7%	62.8%	9.8%	39.7%	62.1%
Kuser RF-T	0.9303	0.8314	0.4781	0.6323	0.7765	0.0002	0.4895	0.9087	0.9279	0.6420
Kuser i RF-T	0.9238	0.8223	0.461	0.5992	0.7586	-0.006	0.4463	0.8594	0.9102	0.5778
Kuser s RF-T	0.9368	0.8404	0.4952	0.6653	0.7945	0.0062	0.5327	0.9579	0.9457	0.7061
Kprod RF-T	0.9601	0.8821	0.7067	0.6201	0.4375	0.0008	0.3598	0.9018	0.5899	0.3741
Kprod i RF-T	0.955	0.874	0.6873	0.5872	0.4219	-0.023	0.3244	0.8511	0.5633	0.3248
Kprod s RF-T	0.9652	0.8902	0.726	0.653	0.4531	0.0246	0.3953	0.9525	0.6166	0.4234

Estos resultados globales enmascaran, sin embargo, diferencias importantes cuando se analizan por clases. En el Cuadro 2 puede verse como funcionan los diferentes modelos de clasificación para cada una de las clases por separado. En este cuadro se incluyen el kappa de usuario que indica el grado de ausencia de error de comisión y el del productor que indica el grado de ausencia de error de omisión. Ambos índices se acompañan de sus intervalos de confianza para un nivel de significación de 0,05. Se han resaltado con negrita los mayores valores de kappa de productor o usuario para cada caso. En caso de no existir diferencia estadísticamente significativa entre dos métodos se resaltan ambos.

Las superficies naturales (bosque y matorral) se clasifican de manera bastante correcta tanto con SMAP como con Random Forest, beneficiándose en ambos métodos de la inclusión de variables de textura. Las superficies de bosque (clase 1) obtienen los mejores resultados con SMAP sin variables de textura (kappa de usuario $0,9653 \pm 0,0047$ y kappa de productor $0,9748 \pm 0,004$). Al añadir variables de textura mejora significativamente el kappa del productor pero disminuye el del usuario. Las superficies de matorral (clase 2) obtienen los mejores resultados con SMAP y variables de textura (kappa de usuario $0,9076 \pm 0,0073$ y kappa de productor $0,8754 \pm 0,0081$), sin embargo el kappa de usuario mejora al eliminar las variables de textura.

Las zonas de cultivo presentan más problemas. Los cultivos arbóreos (clases 3 y 4, la primera en secano y la segunda en regadío) muestran unos errores de omisión y comisión entorno al 30 % que mejoran algo para el algoritmo SMAP al añadir variables de textura al modelo. Los cultivos arbóreos de secano obtienen de nuevo los mejores resultados con SMAP incluyendo variables de textura (kappa de usuario $0,784 \pm 0,0191$ y kappa de productor $0,6132 \pm 0,0199$). Sin embargo en este caso el kappa del productor mejora en el caso de la clasificación de Random Forest incluyendo o no variables de textura. En el caso del arboreo por regadío SMAP con variables de textura es el método que obtiene mejores resultados (kappa de usuario $0,6649 \pm 0,0285$ y kappa de productor $0,8471 \pm 0,0246$) sin que ningún otro método lo supere en ninguno de los dos indicadores.

Los cultivos herbáceos de secano (clase 5) siguen un patrón similar a los cultivos arbóreos de regadío siendo la clasificación con SMAP y variables de textura la que obtiene los indicadores más altos (kappa de usuario $0,8256 \pm 0,0143$ y kappa de productor $0,6212 \pm 0,0156$). Sin embargo la clase 6 (cultivo herbáceo de regadío) muestra unos errores de omisión y comisión elevadísimos, cercanos al 100%. Se trata de un caso de confusión sistemática con otras clases que se analizará más adelante al estudiar las matrices de confusión.

La clase 7 (zona urbana) muestra errores de omisión y comisión relativamente elevados que se estudiará con más detalle posteriormente. En todo caso es el algoritmo Random Forest incluyendo variables de textura el que ofrece mejores resultados (kappa de usuario $0,4895 \pm 0,0432$ y kappa de productor $0,3598 \pm 0,0354$). Aunque en realidad los valores del kappa del productor de los cuatro métodos pueden considerarse todos significativamente iguales.

La clase 8 (agua) se clasifica en general de forma muy correcta, los errores de comisión y omisión al utilizar variables de textura, posiblemente debido a la homogeneidad de las celdillas vecinas de agua que no se da en otras cubiertas con baja reflectividad. Sin embargo esta mejora no resulta estadísticamente significativa. El método de Random Forest con variables de textura es el que mejores resultados ofrece (kappa de usuario

0,9087±0,0492 y kappa de productor 0,9018±0,05), sin embargo las diferencias no llegan a ser en muchos casos estadísticamente significativas.

En el caso de la clase 9 (suelo desnudo) es SMAP con variables de textura el método con mejores resultados (kappa de usuario 0,8382±0,0201 y kappa de productor 0,8442±0,0199). Random Forest con variables de textura alcanza un mayor kappa de usuario pero el kappa de productor es considerablemente más bajo.

En las zonas de vid es Random Forest el que mejores resultados alcanza (incluyendo o no variables de textura). En este último caso se obtiene un kappa de usuario de 0,6420±0,0642 y un kappa de productor de 0,3741±0,0493).

Las Cuadros 3 a 5 muestran las matrices de confusión obtenidas con SMAP y Random Forest tanto al incluir como al no incluir variables de textura. Debido a que sus resultados de los índices globales eran menores no se incluyen las obtenidas con los modelos de máxima verosimilitud o mínima distancia. En dichos cuadros, la correspondencia entre identificadores y usos es la siguiente: 1: Bosque, 2: Matorral, 3: cultivo arbóreo de secano, 4: cultivo arbóreo de regadío, 5: cultivo herbáceo de secano, 6: cultivo herbáceo de regadío, 7: Urbano, 8: Agua, 9: Suelo desnudo y 10: Vid

Cuadro 3
MATRIZ DE CONFUSIÓN DEL ALGORITMO SMAP
SIN VARIABLES DE TEXTURA

	1	2	3	4	5	6	7	8	9	10
1	7959	152	0	4	0	0	0	44	0	0
2	54	8306	5	0	54	3	368	2	3	0
3	0	73	1206	6	182	5	0	0	21	37
4	0	5	18	568	1	247	0	1	0	0
5	0	0	246	0	2298	0	34	0	166	39
6	65	108	696	245	1282	38	1	0	0	88
7	23	480	84	0	0	0	317	0	0	0
8	0	18	10	8	0	8	0	86	0	0
9	2	107	44	0	59	1	0	0	1139	0
10	0	23	136	27	170	0	0	0	0	208

Otro problema de cierta importancia es la confusión entre matorrales y zonas urbanas. Posiblemente se deba a fenómenos de expansión urbana o nuevas urbanizaciones que hayan generado errores en áreas de entrenamiento o validación. El algoritmo SMAP se ve algo menos afectado por este hecho que Random Forest. Los matorrales tienden también a confundirse en algunos casos con suelo desnudo debido posiblemente a la dificultad de establecer un límite preciso entre el suelo desnudo y el matorral de muy baja densidad.

Las zonas agrícolas presentan también cierta tendencia a confundirse entre sí, especialmente entre herbáceos de secano, de regadío y arbóreo de secano. El arbóreo de regadío parece distinguirse mejor. Evidentemente las diferentes circunstancias fenológicas o de ciclos de cultivo explican estos problemas.

Cuadro 4
MATRIZ DE CONFUSIÓN DEL ALGORITMO RANDOM FOREST SIN VARIABLES DE TEXTURA

	1	2	3	4	5	6	7	8	9	10
1	7821	411	45	105	0	12	1	15	0	0
2	203	8288	109	26	288	2	407	0	10	25
3	2	263	1809	45	764	14	25	0	327	52
4	54	0	10	551	0	222	0	1	4	0
5	0	34	193	0	1986	17	1	0	191	34
6	1	10	124	130	928	35	0	0	0	112
7	17	208	71	1	15	0	277	0	15	2
8	5	3	15	0	0	0	0	117	0	0
9	0	48	5	0	37	0	4	0	782	0
10	0	7	64	0	28	0	5	0	0	147

Cuadro 5
MATRIZ DE CONFUSIÓN DEL ALGORITMO SMAP CON VARIABLES DE TEXTURA

	1	2	3	4	5	6	7	8	9	10
1	7777	74	0	9	0	0	0	0	0	0
2	105	8496	33	3	48	0	346	0	19	1
3	0	66	1566	0	254	29	0	0	25	9
4	94	3	1	732	4	249	0	1	0	0
5	0	16	222	0	2689	4	6	0	153	69
6	16	33	404	103	945	6	48	0	0	125
7	71	437	74	4	9	1	317	9	0	5
8	24	3	41	7	0	13	0	123	0	1
9	6	139	39	0	22	0	0	0	1132	0
10	10	5	65	0	75	0	3	0	0	162

Cuadro 6
MATRIZ DE CONFUSIÓN DEL ALGORITMO RANDOM FOREST CON VARIABLES DE TEXTURA

	1	2	3	4	5	6	7	8	9	10
1	7877	211	54	117	0	12	2	12	0	0
2	149	8561	131	57	282	2	411	0	14	33
3	1	261	1818	83	883	21	25	0	312	63
4	51	0	9	542	0	237	0	0	3	0
5	0	24	195	0	1969	16	1	0	193	35
6	0	9	148	58	834	13	4	1	0	99
7	18	155	60	1	24	0	268	0	6	1
8	7	2	2	0	0	1	0	120	0	0
9-	0	44	4	0	2	0	9	0	801	0
10	0	5	24	0	48	0	0	0	0	141

Las figuras 3 a 5 muestran los mapas obtenidos con los cuatro modelos de clasificación que mejores resultados han obtenido. Se observa una diferencia fundamental entre los mapas generados con SMAP y los generados con Random Forest. Los primeros incluyen polígonos mucho mayores de un uso homogéneo. Especialmente relevante es el caso de los herbáceos de regadío. Se observa como SMAP genera un área de gran tamaño para este uso en el Sur de la cuenca mientras que en el mapa generado con Random Forest tan solo aparecen pequeñas manchas.

Figura 2
CLASIFICACIÓN CON SMAP SIN VARIABLES DE TEXTURA

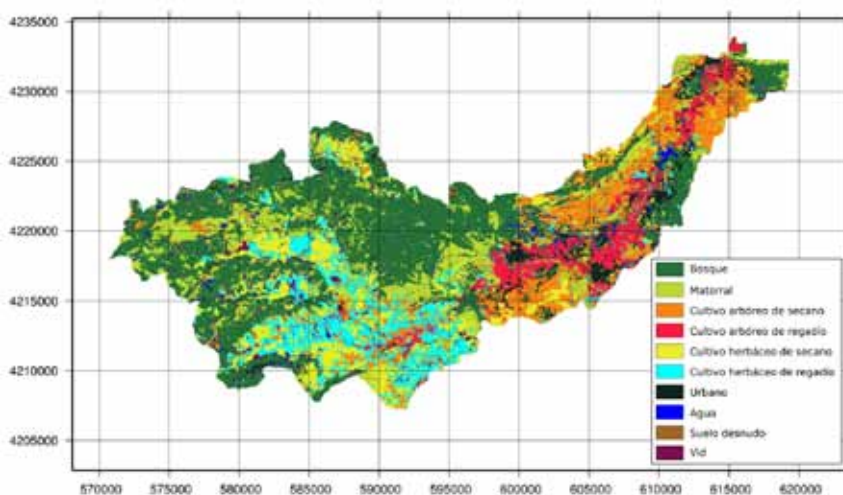
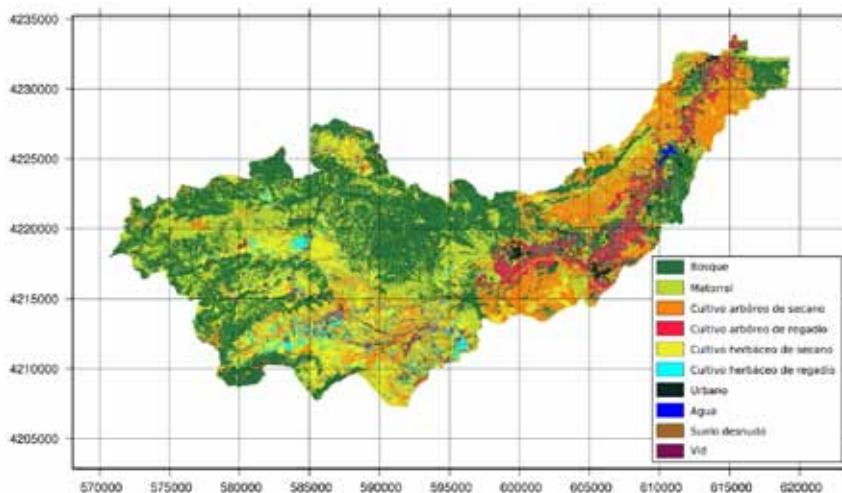


Figura 3
CLASIFICACIÓN CON RANDOM FOREST SIN VARIABLES DE TEXTURA



Es interesante reseñar como la incorporación de variables de textura tiende a aumentar el tamaño de las manchas de regadío en el mapa de Random Forest y a disminuirla en el mapa de SMAP. De este modo se produce una cierta convergencia entre ambos modelos de clasificación.

Aunque en principio el tener polígonos de mayor tamaño pueda ser una propiedad deseable en una mapa de usos del suelo elaborado mediante teledetección, en este caso los resultados de Random Forest parecen algo más realistas

Figura 4
CLASIFICACIÓN CON SMAP INCLUYENDO VARIABLES DE TEXTURA

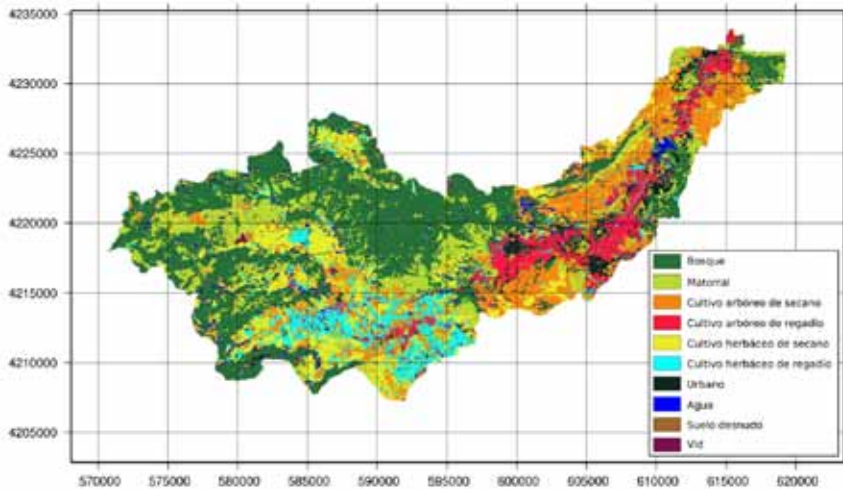
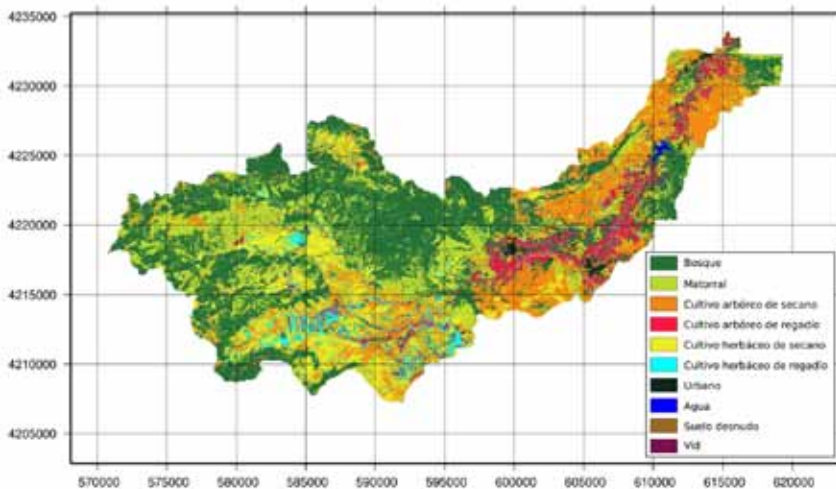


Figura 5
CLASIFICACIÓN CON RANDOM FOREST INCLUYENDO VARIABLES DE TEXTURA



Finalmente el Cuadro 7 muestra una comparación de la superficie ocupada por cada una de las clases con los porcentajes registrados en el mapa de usos del suelo. La primera cuestión a tener en cuenta es que la leyenda de usos de Corine no corresponde exactamente con el esquema de clasificación utilizado en este trabajo. Por ello es normal que se observen ciertas discrepancias.

Cuadro 7
COMPARACIÓN ENTRE LOS PORCENTAJES DE OCUPACIÓN OBTENIDOS CON LOS DIFERENTES MÉTODOS CON LOS USOS DE SUELO SEGÚN CORINE LAND COVER

USO	Corine	RF	SMAP	RF-T	SMAP-T
Bosque	38.8 %	35.3 %	35.42 %	35.30 %	34.63 %
Matorral	12.63 %	22.7 %	15.21 %	22 %	16.22 %
Arbóreo de secano	12.88 %	18.6 %	13.86 %	19.02 %	16.23 %
Arbóreo de regadío	9.6 %	4.24 %	6.06 %	4.82 %	6.32 %
Herbáceo de secano + vid	15.48 %	12.18 %	11.51 %	11.33 %	12.17 %
Herbáceo de regadío	4.32 %	4.11 %	10.77 %	4.40 %	7.42 %
Urbano	2.2 %	2.13 %	4.61 %	2.19 %	3.68 %
Agua	0.14 %	0.36 %	1.71 %	0.49 %	2.43 %
Suelo desnudo	3.89 %	0.37 %	0.84 %	0.43 %	0.91 %

Las zonas de bosque presentan poca discrepancia utilizando cualquiera de los métodos, las de matorral se sobreestiman bastante con SMAP y obtienen un resultado muy similar con Random Forest. El arbóreo de secano se sobreestima con todos los métodos y el de regadío se infraestima con todos los métodos.

Las zonas de agua aparecen sobreestimadas respecto a Corine por todas las clasificaciones. La razón habría que buscarla por una parte en que las balsas de riego han sido identificadas en las imágenes de satélite y no aparecen en el proyecto Corine y por otra en el mayor tamaño que presentan en las imágenes el pequeño embalse del Argos.

El suelo desnudo resulta muy infraestimado en todos los casos. Se trata, a nuestro juicio, de una diferencia de criterio a la hora de establecer el límite entre matorral y suelo desnudo. Los responsables del proyecto Corine consideraron como suelo desnudo zonas de matorral muy poco denso que, en nuestras áreas de entrenamiento, se consideraron como matorral. Por ello el matorral aparece sobreestimado y el suelo desnudo infraestimado,

Las clases en las que cabe esperar pequeñas manchas de unos pocos píxeles (urbano o agua) se sobreestiman con SMAP. Sin duda la clasificación contextual tiende a homogeneizar las áreas cercanas y a generar polígonos excesivamente grandes.

VI. CONCLUSIONES

Teniendo en cuenta todos los resultados obtenidos en los apartados anteriores, se pueden sacar diversas conclusiones:

- Todos los modelos mejoran de manera importante al utilizado como base, de hecho, el que menos lo mejora es el de Máxima Probabilidad y aún así tiene un porcentaje de acierto de entre un 20 y un 30% puntos porcentuales más.

- Tanto Random Forest como SMAP obtienen unos resultados muy parecidos, siendo el segundo el que mejores porcentajes de acierto obtiene.
- Los errores a la hora de clasificar los distintos usos del suelo son prácticamente los mismos para todos los métodos.
- Los usos del suelo agrícolas son los que mayores confusiones introducen a la hora de realizar la clasificación. En concreto el cultivo herbáceo de regadío es el más conflictivo, de hecho la mayoría de métodos presentan un error de comisión de más del 90
- Teniendo en cuenta que en este trabajo se utilizan 10 clases y la mayoría de trabajos de análisis de clasificación utilizan entre 3 y 7 (Canran Liu et al., 2006), si agrupáramos las clases destinadas a cultivo, que son las que mayores errores introducen, en una sola utilizando así 6 clases, los resultados serían mucho mejores.
- Estos errores que más se repiten y que se corresponden a los cultivos, son por otro lado comprensibles, ya que, teniendo en cuenta las características de falta de humedad de la cuenca del río Argos, es muy difícil distinguir, mediante imágenes de satélite, los cultivos de secano de los de regadío. Mucho más difícil resulta distinguir los árboles de los herbáceos tanto en secano como en regadío.
- Las clases con mayores porcentajes de acierto son las correspondientes a usos del suelo naturales, como el matorral, el bosque o el agua. Sobre todo los dos últimos, ya que el matorral se confunde con los cultivos herbáceos debido a su parecido.
- La utilización de variables de textura mejora los resultados pero quizás menos de lo que en un principio se pensaba. Esto es debido a que los márgenes de mejora son muy escasos, teniendo en cuenta que los errores se corresponden con los usos del suelo destinados al cultivo y éstos son muy difíciles de solucionar.

Como conclusión final decir que los resultados aunque son buenos, no son tan satisfactorios como se pensó en un primer momento debido a la utilización de 5 clases de usos del suelo destinadas a cultivos, algo que por otro lado no es habitual en la mayoría de trabajos destinados a analizar clasificaciones de imágenes de satélite. En cuanto a los resultados obtenidos por los distintos métodos de clasificación, comentar que los tres métodos que se comparan con el utilizado como base, Mínima Distancia, lo mejoran de manera importante, algo que se encuentra dentro de lo esperado.

REFERENCIAS

- ALONSO, F.; GOMARIZ, F. y CÁNOVAS, F. (2010): «Análisis temporal de los cambios de usos del suelo en la Cuenca del Segura mediante teledetección. Implicaciones sobre la degradación». *Cuaternario y Geomorfología*, 24, 71-86.
- ATKINSON, P.M. y LEWIS, P. (2000) «Geostatistical classification for remote sensing. An introduction». *Computers and Geosciences*, 26, 361-371.
- BENEDIKTSSON, J.A. y SVEINSSON, J.R. (1997): «Feature extraction for multisource data classification with artificial neural networks». *International Journal of Remote Sensing*, 18, 727-740.
- BERBEROGLU, H., YIN, J. y PILON, L. (2007): «Texture classification of Mediterranean land cover». *Rev. International Journal of Applied Earth Observation and Geoinformation*, 9, 322-334.

- BIVAND, R. (2007): «Using the R-GRASS Interface: Current Status». *OSGeo Journal*, 1, 36-38
- BOUMAN, C. y SHAPIRO (1994): «A multiscale random field model for Bayesian image segmentation». *IEEE Trans. On image Processing*, 3, 2, 162-177.
- BREIMAN, J. (2001): «Random Forest». *Machine Learning*, 45, 5-32.
- CEBRIÁN ABELLÁN, C. (2007): «El Noroeste», en Romero Díaz A. y Alonso Sarría F. *Atlas Global de la Región de Murcia* Ediciones La verdad.
- CÁNOVAS GARCÍA, F. (2012): *Análisis de imágenes basado en objetos (OBIA) y aprendizaje automático para la obtención de mapas de coberturas del suelo a partir de imágenes de muy alta resolución espacial*. Tesis doctoral. Universidad de Murcia.
- CHÁVEZ, P.S. (1988): «An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data». *Remote Sensing of Environment*, 24, 459-479.
- CHENG, H. y BOUMAN, C. (2001). *Multiscale Bayesian segmentation using a trainable context model*. «IEEE Trans. On image Processing», 10, 4, 1621057-7149.
- CHUVIECO SALINERO, E. (2006): *Teledetección ambiental. La observación de la Tierra desde el Espacio*. Barcelona, Ariel.
- CONGALTON, R.G. y GREEN, K. (2008): «Assessing the accuracy of remotely sensed data». In: *Principles and Practices*. CRC Press.
- CUTLER, D., EDWARDS, T.C., BEARD, K.H., CUTLER, A., HESS, K.T., GIBSON, J. y LAWLER, J.J. (2007): «Random forest for classification in ecology». *Ecology* 88 (11), 2783-2792.
- EHSANI, A.H. (2011): «Evaluation of Sequential Maximum a Posteriori (SMAP) method for Land Cover Classification». *Geomatics 90* (National Conference & Exhibition).
- FOODY, G.M. (2002): «Status of land cover classification accuracy assessment». *Remote Sensing Environment*, 80, 185-201.
- GHIMIRE, B., ROGAN, J. y MILLER, J. (2010): «Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic». *Remote Sensing Letters*, 1 (1), 45-54.
- IHAKA, R. y GENTLEMAN, R. (1996): «A language for Data Analysis and Graphics». *Journal of Computational and Graphical Statistics*, 5 (3), 299-314.
- LANDIS, J.R. y KOCH, G.G. (1977): «The Measurement of Observer Agreement for Categorical Data». *Biometrics*, 33(1), 159-174.
- LIAM, A. Y WIENER, M. (2002): «Classification and Regression by randomForest». *News*, 2:3, 18-22.
- LIU et al. (2006): «Comparative assessment of the measures of thematic classification accuracy». *Remote Sensing of Environment*, 107, 606-616.
- McCAULEY, J.D. y ENGEL, B.A. (1995): «Comparison of Scene Segmentations: SMAP, ECHO and Maximum Likelihood», *IEEE Trans. on Geoscience and Remote Sensing*, 33(6): 1313-1316.
- NETELER, M. y MITASOVA, H. (2009): *Open source gis: A GRASS GIS APPROACH*. Springer, New York, 3ª edición.
- PAL, M. (2005): «Random forest classifier for remote sensing classification». *International Journal of Remote Sensing*, 26, 217-222.

- PONTIUS, R. G. y MILLONES, M. (2011): «Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment». *International Journal of Remote Sensing*, 32(15): 4407-4429.
- PRASAD, A.M., IVERSON, L.R. y LIAW, A. (2006): «Newer classification and regression tree techniques: bagging and random forests for ecological prediction». *Ecosystems*, 9, 181-199.
- REES, G. (2005): *The remote sensing data book*. Cambridge University Press.
- RICHARDS, J.A. y JIA, X. (1999): *Remote Sensing Digital Image Analysis, An Introduction*. Springer, Berlin.
- SWAIN, P.H. y DAVIS, S.M. (1978): *Remote Sensing: The Quantitative Approach*. McGraw-Hill.
- TEILLET, P.M., GUINDON, B. y GOODEONUGH, D.G. (1982): «On the slope aspect correction of multispectral scanner data». *Canadian Journal of Remote Sensing*, 8, 84-106.
- TOWNSEND, J.R.G. (1992): «Land cover». *International Journal of Remote Sensing*, 13, 1319-1328.
- TSO, B. Y MATHER, P. (2009): *Classification Methods for Remotely Sensed Data* CRC. Press Taylor & Francis Group.
- URREA GALES, V. (2009): *Detección de interacciones genéticas asociadas a enfermedades complejas. Aplicación al cáncer de vejiga*. «Tesina o Proyecto, Universitat Politècnica de Catalunya».
- WITTEN, I. H. y FRANK, E. (1999): *Data mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Morgan Kaufmann Publishers, San Francisco.
- ZHOU, Q. y ROBSON, M. (2001): «Contextual information is ultimately necessary if one is to obtain accurate image classifications». *International Journal of Remote Sensing*, 22:3457-3470.

