

GENERACIÓN DE MAPAS DE USOS DE SUELO PERIÓDICOS A ESCALA REGIONAL CON IMÁGENES MODIS: APLICACIÓN A LA COMUNIDAD VALENCIANA

R. Niclòs (*), M. J. Estrela (**), J. A. Valiente (*) y M. J. Barberà (*).

(*) Unidad Mixta CEAM-UVEG. Fundación Centro de Estudios Ambientales del Mediterráneo.
Charles Darwin, 14, 46980 Paterna niclos@ceam.es

(**) Unidad Mixta CEAM-UVEG. Departamento de Geografía. Universidad de Valencia.
Blasco Ibáñez, 28. 46010 Valencia.

RESUMEN

En este trabajo se propone una metodología para la generación periódica de mapas de tipologías de superficies adecuados a nivel regional, que permitan, por ejemplo, una correcta asignación de emisividades en la determinación de la temperatura desde satélite. El método usa clases CORINE contrastadas y frecuentes en la zona estudiada como áreas verdad terreno para aplicar una clasificación supervisada sobre imágenes del parámetro BRDF isótropo del producto MCD43A1 de MODIS.

ABSTRACT

This work proposes a methodology to periodically generate land cover classifications at a regional scale, which would permit, e.g., an appropriate assignment of emissivities to determine temperatures from satellites. The method uses CORINE classes contrasted and frequent in the study area as ground truth to apply a supervised classification using images of the isotropic BRDF parameter of the MODIS MCD43A1 product.

Palabras clave: usos de suelo, clasificación supervisada, MODIS, CORINE.

INTRODUCCIÓN

Uno de los requisitos de partida en cualquier estudio sobre interacciones superficie-atmósfera es el conocimiento del tipo de superficie, siendo necesario disponer de mapas de clasificación de suelos.

La base de datos CORINE (CEC, 1995) proporciona una cartografía detallada de coberturas (escala 1:100.000), pero sin embargo esta información es relativamente estática (decenal), y hemos comprobado que existen errores con respecto de la situación real actual.

Además, aporta demasiadas clases diferentes, y su resolución espacial es extremadamente fina para ciertas aplicaciones sinópticas, por lo que, en muchos casos, puede ser necesario reducir su detalle. Actualmente existen también mapas de tipologías de suelos generados a partir de imágenes de satélite de media y baja resolución espacial, como el producto estático LSASAF-USGS-IGBP_LANDCOV de 3km de resolución creado para el análisis de imágenes Meteosat Segunda Generación (landsaf.meteo.pt), o el producto MOD12Q1 generado con imágenes MODIS de 1km de resolución (lpdaac.usgs.gov) (ver Figura 1). Ambos productos proporcionan una

clasificación IGBP (Internacional Geosphere-Biosphere Program) que distingue un total de 17 clases diferentes. Sin embargo, la comprobación de estos productos frente a datos verdad terreno muestra también importantes errores en nuestra región. Por ejemplo, los productos MOD12Q1 y LSASAF clasifican como "bosque mixto" y "bosque aciculifolio" a una zona extensa de marjal dedicada al cultivo del arroz en la Albufera de Valencia. Por ello, el objetivo de este trabajo es proponer una metodología para la generación periódica de mapas de tipologías de superficies adecuados a nivel regional, que facilite, por ejemplo, una adecuada estimación de emisividades para la obtención de la temperatura desde satélite.

METODOLOGÍA

La metodología que aquí proponemos se basa en la aplicación de una clasificación supervisada de máxima probabilidad, *Maximum Likelihood* (Richards 1999), sobre imágenes MODIS de reflectividad espectral a 500x500m² de píxel, resolución que consideramos idónea para estudios sinópticos a nivel regional, siendo nuestro objetivo actual la generación de mapas periódicos de tipologías de suelo en la Comunidad Valenciana.

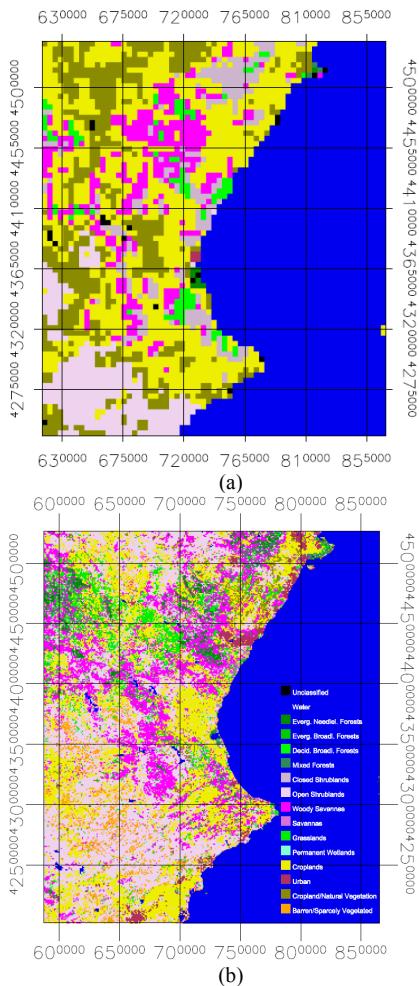


Figura 1.- Recortes de los productos (a) LSASAF y (b) MOD12Q1 para la Comunidad Valenciana (UTM, European 1950, Uso 30N).

En concreto, el producto MODIS utilizado es el MCD43A1, que proporciona, cada 16 días, los parámetros asociados a un modelo de distribución de reflectividad bidireccional (BRDF). Este producto usa un modelo semiempírico lineal de tipo Kernel-driven (Roujean et al. 1992) que toma la forma:

$$R(\theta_i, \theta_o, \phi, \lambda) = \sum_k f_k(\lambda) K_k(\theta_i, \theta_o, \phi) \quad (1)$$

donde R es la reflectividad bidireccional bajo ángulos cenitales de iluminación y observación θ_i y θ_o , con un ángulo acimutal relativo ϕ , y una longitud de onda λ . Las funciones o kernels K_k son

expresiones geométricas que caracterizan el comportamiento anisótropo de las cubiertas vegetales, y normalmente suelen ser tres (Roujean et al. 1992): un kernel constante que representa la dispersión múltiple con una distribución aproximadamente isótropa, un kernel geométrico que describe la dispersión simple que se produce en los elementos tridimensionales de la superficie, K_{geo} , y un kernel volumétrico asociado a la dispersión simple producida en el interior de los elementos de la escena (por ejemplo, dentro de la estructura de la vegetación), K_{vol} . Así, la ecuación general (1) puede escribirse como:

$$\begin{aligned} R(\theta_i, \theta_o, \phi, \lambda) &= f_{iso}(\lambda) + f_{geo}(\lambda)K_{geo}(\theta_i, \theta_o, \phi) + (2) \\ &+ f_{vol}(\lambda)K_{vol}(\theta_i, \theta_o, \phi) \end{aligned}$$

donde $f_{iso}(\lambda)$, $f_{geo}(\lambda)$, $f_{vol}(\lambda)$ son factores de peso asociados a cada kernel. De acuerdo con el convenio introducido por Roujean et al. (1992), estos kernels se expresan de manera que cuando el sol y el observador están en el zenith ($\theta_i=\theta_o=0$), $K_{vol}(0,0,\phi)=K_{geo}(0,0,\phi)=0$, y así $R(\theta_i, \theta_o, \phi, \lambda)=f_{iso}(\lambda)$. Por ello, $f_{iso}(\lambda)$ se define como la reflectividad de la superficie cuando ésta se observa en dirección nadir con el sol sobre el zenith. El producto MCD43A1 proporciona los 3 parámetros f_{iso} , f_{geo} , f_{vol} asociados a las bandas 1 a 7 de MODIS (con longitudes de onda centrales de 645,5nm, 856,5nm, 465,6nm, 553,6nm, 1241,6nm, 1629,1nm, y 2114,1nm, respectivamente). Ahora bien, de acuerdo con la definición anterior, es el parámetro f_{iso} el que puede considerarse como una reflectividad normalizada de los efectos de anisotropía y, así, proporcionar la base para intercomparar datos adquiridos por un sensor bajo diferentes ángulos de observación y de iluminación (Verger et al. 2005). Por ello, y dado que nuestra finalidad es generar periódicamente mapas de tipos de superficies, utilizamos este parámetro f_{iso} para la clasificación.

Además, la aplicación de una clasificación supervisada requiere áreas de información verdad terreno de entrenamiento que sirvan como referencia, es decir, áreas en las que estemos seguros del tipo de superficie existente. Para ello, podemos definir regiones de interés cartografiando áreas conocidas sobre la propia imagen, o bien tomar como base cartografías ya existentes. En este trabajo, partimos de la base CORINE, de donde seleccionamos los polígonos pertenecientes a las clases más frecuentes en nuestra región (ver Figura 2). A continuación, elegimos diversos polígonos pertenecientes a cada clase de los que disponíamos de información de campo, y los contrastamos y ajustamos frente a ortofotos, asegurando su

homogeneidad y representatividad como clases. Tras esto, analizamos la signatura espectral del parámetro f_{iso} para cada una de las clases, es decir, su variación dentro de las bandas 1 a 7 de MODIS. Con esto evaluamos la capacidad de discriminación entre clases con el fin de seleccionar las clases más óptimas para nuestra clasificación. La Figura 3 muestra un ejemplo de los espectros obtenidos. Las clases mostradas en la Figura 3a son claramente discriminables por su signatura, pero, sin embargo, las signaturas mostradas en la Figura 3b son muy similares (con diferencias entre ambas inferiores a sus desviaciones estándar), lo que indica que estas clases no son discriminables, por lo que decidimos juntarlas en una sola clase "matorral". Este mismo criterio fue aplicado al resto de clases inicialmente seleccionadas (mostradas en la Figura 2), quedándonos finalmente en 9 clases: bosque, matorral, áreas urbanas, cereal/barbecho, secano (vid), secano (olivo), regadio, arrozales y agua.

Finalmente, tomando los polígonos seleccionados para cada clase como áreas de referencia o entrenamiento, la clasificación supervisada se aplicó sobre las imágenes f_{iso} de las bandas 1 a 7 de MODIS, descartando para ello los píxeles donde el producto MCD43A2 (asociado al MCD43A1) no indicara una calidad óptima.

EVALUACIÓN DE LA PRECISIÓN

Para estimar la precisión de una clasificación calculamos la matriz de confusión, la cual compara los resultados de la clasificación frente a áreas verdad terreno, especificando el número total de píxeles de referencia que siendo de un tipo dado han sido asignados a cada una de las clases. A partir de esta matriz, se calculan diversos parámetros que estiman su precisión, como: a) la precisión global, que cuantifica el número de píxeles correctamente clasificados, b) la precisión del productor, que indica la probabilidad de que un pixel de la clase i está correctamente clasificado, y c) la precisión del usuario, que indica la probabilidad de que un pixel clasificado como clase i corresponda realmente a dicha clase (ver expresiones en Tabla 1). Las precisiones de productor y usuario están relacionadas con los errores de "omisión" y "comisión". Además, el coeficiente Kappa calcula el acuerdo entre la imagen clasificada y la realidad observada debido únicamente a la exactitud de la clasificación, suprimiendo el acuerdo que cabría esperar simplemente por azar.

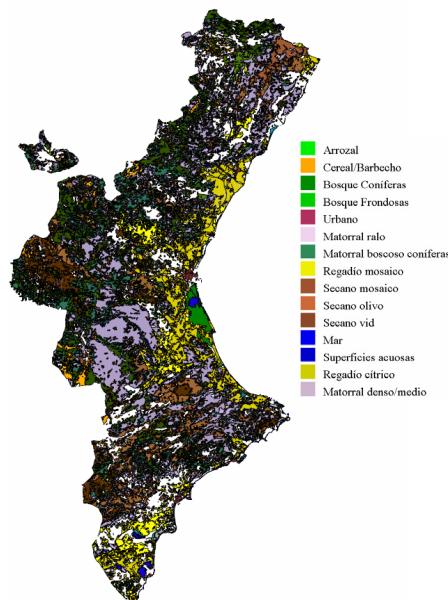


Figura 2.- Cobertura de las clases CORINE seleccionadas para la Comunidad Valenciana.

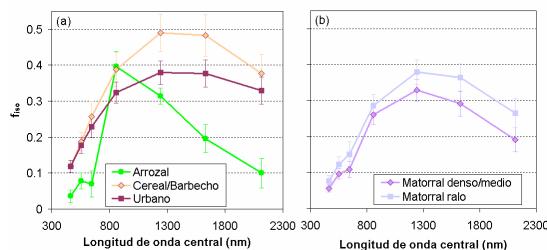


Figura 3.- Variación de f_{iso} con las bandas MODIS.

Tabla 1.- Parámetros de precisión de clasificación.

| | |
|-------------------------|--|
| Precisión global | $P = \sum_{i=1}^m x_{ii} / N$ |
| Precisión del productor | $P_p = x_{ii} / x_{\Sigma i}$ |
| Precisión del usuario | $P_u = x_{ii} / x_{i\Sigma}$ |
| Coeficiente Kappa | $\kappa = \frac{N \sum_{i=1}^m x_{ii} - \sum_{i=1}^m x_{i\Sigma} x_{\Sigma i}}{N^2 - \sum_{i=1}^m x_{i\Sigma} x_{\Sigma i}}$ |

m = número total de clases.

N = número total de píxeles en las m clases de referencia.

x_{ii} = elementos de la diagonal de la matriz de confusión.

$x_{i\Sigma}$ = suma de los píxeles de la clase i de referencia.

$x_{\Sigma i}$ = suma de los píxeles clasificados como la clase i .

Con estos parámetros evaluamos tanto la bondad del método de clasificación, usando las regiones de interés seleccionadas para cada clase en el proceso de entrenamiento, como la precisión de la clasificación obtenida, utilizando áreas verdad terreno de validación, no usadas como áreas de entrenamiento. Además de evaluar los resultados de la clasificación realizada usando las bandas 1 a 7 de MODIS, también analizamos los resultados al añadir el NDVI o el RSSI (Relative Structural Scattering Index, Gao et al. 2003), relacionado con la estructura de la vegetación, como una banda más, ambos generados a partir del mismo producto MCD43A1. Los resultados mejoraban ligeramente con el uso de alguna de estas bandas adicionales, obteniéndose las mejores precisiones para la combinación de las bandas 1 a 7 más el NDVI. La Figura 4 muestra la clasificación finalmente obtenida, y la Tabla 2 recoge los parámetros de precisión calculados para esta combinación de bandas, tanto para las áreas de entrenamiento como para las de validación. Esta tabla muestra que la bondad de la fase de entrenamiento es del 80% mientras que su precisión, comprobada frente a áreas verdad terreno de validación, es del 70%. Estas precisiones son relativamente elevadas si consideramos que se trata de una clasificación realizada sobre imágenes de 500x500m² de pixel.

Tabla 2.- Precisión de la clasificación (Fig. 4).

| | Entrenamiento | | Validación | |
|-----------------------------|--------------------|--------------------|--------------------|--------------------|
| | P _p (%) | P _u (%) | P _p (%) | P _u (%) |
| Bosque | 78 | 76 | 78 | 48 |
| Matorral | 72 | 81 | 66 | 90 |
| Urbano | 91 | 62 | 82 | 76 |
| Cereal/Barbecho | 85 | 44 | 81 | 68 |
| Secano (vid) | 85 | 96 | 49 | 45 |
| Secano (olivo) | 84 | 60 | 49 | 62 |
| Regadio | 84 | 91 | 88 | 79 |
| Arrozal | 96 | 90 | 97 | 100 |
| Coeficiente Kappa | 0,73 | | 0,64 | |
| Precisión global (%) | 79 | | 70 | |

CONCLUSIONES

En este trabajo proponemos un método para la generación periódica, cada 16 días si se desea, de mapas de usos de suelo a escala regional a partir de imágenes MCD43A1 de MODIS. Estos mapas serían intercomparables, ya que partimos del uso del parámetro f_{iso} , y los resultados demuestran que se obtendrían con una precisión relativamente elevada. Estos mapas son útiles para caracterizar superficies y también para la determinación de emisividades en estudios de la temperatura superficial.

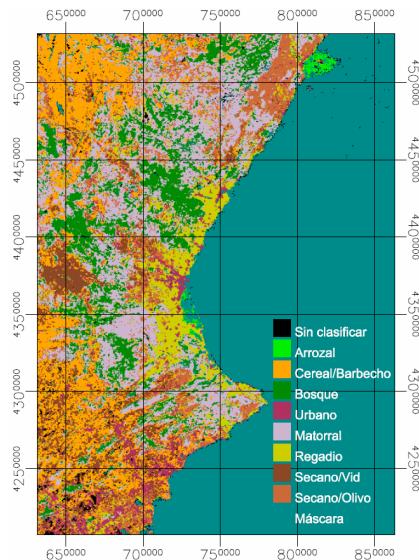


Figura 4.- Ej. de clasificación para agosto de 2007.

BIBLIOGRAFÍA

- CEC (Commission of the European Communities). 1995. CORINE Land Cover Technique Guide, p163.
 Gao, F., Schaaf, C.B., Strahler, A.H., Jin, Y., y Li, X. 2003. Detecting vegetation structure using a kernel-based BRDF model. *Remote Sens. Environ.*, 86: 189-205.
- Verger, A., Camacho-de Coca, F., y Meliá, J. 2005. Revisión de los modelos paramétricos de BRDF. *Revista de Teledetección*, 23: 65-80.
- Richards, J.A. 1999. *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin, p. 240.
- Roujeau, J.L., Leroy, M., y Deschamps, P.Y. 1992. A bidirectional reflectance model of the Earth's surface for the correction of remote sensing data. *J. Geophys. Res.*, 97: 20455-20468.

AGRADECIMIENTOS

Queremos agradecer la apreciable colaboración del Dr. J.A. Alloza. Este estudio ha sido financiado por el Ministerio de Innovación y Ciencia, y el Fondo Social Europeo, a través de los proyectos CGL2007-65774/CLI, CGL2008-04550/CLI, CONSOLIDER-INGENIO CSD2007-00067 y el contrato *Juan de la Cierva* de la Dra. R. Niclòs.