

CLASIFICACIÓN PERIÓDICA DE COBERTURAS TERRESTRES A ESCALA REGIONAL CON IMÁGENES MODIS

RAQUEL NICLÒS CORTS*¹, MARÍA JOSÉ ESTRELA NAVARRO**, JOSÉ ANTONIO VALIENTE PARDO* Y MARÍA JESÚS BARBERÀ BISBAL*

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

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

RESUMEN

Dada la variabilidad existente en los usos de suelo y el relativo estatismo de los mapas de coberturas terrestres existentes, en este trabajo se propone una metodología para la generación periódica de mapas de tipologías de superficies terrestres adecuados a nivel regional. El método usa polígonos seleccionados de la base CORINE como áreas verdad terreno para aplicar una clasificación supervisada sobre imágenes del parámetro isótropo del modelo BRDF (Función de Distribución de Reflectividad Bidireccional) ofrecido por el producto MCD43A1 de MODIS. El análisis de las matrices de confusión computadas entre las clasificaciones generadas y áreas verdad terreno muestra precisiones totales de entrenamiento cercanas al 80% y de validación del 70%. Estas precisiones resultan relativamente elevadas si consideramos que se trata de clasificaciones realizadas sobre imágenes de 500x500m² de píxel.

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

PERIODIC LAND COVER CLASSIFICATION AT A REGIONAL SCALE BY USING MODIS IMAGES

ABSTRACT

This work proposes a methodology to generate regional land cover maps periodically, due to the variability of land uses and the relatively statism of the existent land cover maps. The method uses polygons selected from the CORINE database as ground-truth areas and applies a supervised classification to images of the isotropic parameter of the BRDF (Bidirectional Reflectance Distribution Function) model given by the MCD43A1 product of MODIS. The analysis of the confusion matrixes computed between the generated classifications and ground-truth areas shows overall training and validation accuracies close to 80% and 70%, respectively. These accuracies can be considered relatively high for classifications developed using images with a spatial

Recibido: 14/10/2009

Aceptada versión definitiva: 28/12/2009

© Los autores
www.geo-focus.org

resolution of 500x500m² pixel.

Key words: land cover, supervised classification, MODIS, CORINE.

1. 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 coberturas terrestres para el momento en que se realicen los estudios. Además, disponer de mapas de usos de suelo es esencial en el ámbito de la gestión sostenible de recursos y en estudios de indicadores ambientales y de cambio climático.

La base de datos CORINE (*Coordination of Information on the Environment*) de la Unión Europea (CEC, 1995) proporciona una cartografía detallada de coberturas a escala 1:100.000, sin embargo esta información es relativamente estática, revisada cada 10 años, y hemos comprobado que existen errores significativos con respecto de la situación real actual. Además, según la aplicación, distingue demasiadas clases diferentes, ya que cuenta con un sistema jerárquico de 44 clases organizado en 3 niveles, y su resolución espacial es extremadamente fina para estudios a media escala y escala sinóptica, por lo que en muchos casos puede ser necesario reducir su detalle.

Existen también otros 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) ([figura 1a](#) y [figura 1b](#), respectivamente). 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 de estudio, la Comunidad Valenciana. Por ejemplo, los productos LSASAF y MOD12Q1 clasifican de modo erróneo, respectivamente como "bosque aciculifolio" y "bosque mixto", a una zona extensa de marjal dedicada al cultivo del arroz en la Albufera de Valencia (4354807m N, 731955m E, UTM, European mean 1950, Uso 30N, ver en la [figura 1](#)).

Por ello, el objetivo de este trabajo es proponer una metodología para la generación periódica de mapas de coberturas terrestres adecuados a nivel regional. Esta metodología puede resultar útil para analizar los usos de suelo, pero también puede servir como base para la determinación de otras variables físicas, como la temperatura, desde satélite.

El apartado siguiente expone la metodología propuesta, describiendo tanto las imágenes de satélite utilizadas, y los parámetros básicos que se pueden obtener de ellas, como la selección de áreas verdad terreno que tomaremos como referencia. El apartado 3 muestra los resultados obtenidos cuando esta metodología se aplica para la generación de mapas de coberturas terrestres para la Comunidad Valenciana. En este apartado se analiza también la precisión de las

clasificaciones obtenidas, tanto en función de las áreas de entrenamiento utilizadas como en función de las bandas de información tomadas como referencia. Finalmente, el apartado 4 presenta las principales conclusiones alcanzadas.

2. 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 $500 \times 500 \text{m}^2$ de píxel, resolución que consideramos adecuada para estudios de patrones globales de variación de magnitudes físicas a nivel regional.

2.1. Imágenes de satélite

El producto MODIS utilizado es el MCD43A1 (Strahler *et al.*, 1999), 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:

$$R(\theta_i, \theta_o, \phi, \lambda) = f_{\text{iso}}(\lambda) + f_{\text{geo}}(\lambda) K_{\text{geo}}(\theta_i, \theta_o, \phi) + f_{\text{vol}}(\lambda) K_{\text{vol}}(\theta_i, \theta_o, \phi) \quad (2)$$

donde $f_{\text{iso}}(\lambda)$, $f_{\text{geo}}(\lambda)$, $f_{\text{vol}}(\lambda)$ son factores de peso asociados a cada kernel. Los kernel K_{vol} y K_{geo} utilizados en este producto son el RossThick (Roujean *et al.*, 1992) y el LiSpace recíproco (Lucht, 1998), por lo que finalmente el modelo BRDF usado se denomina Ross-Li (Strahler *et al.*, 1999).

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, es decir, tanto la iluminación solar como la observación se dan en dirección perpendicular a la superficie. El producto MCD43A1 proporciona los 3 parámetros f_{iso} , f_{geo} y 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 en diferentes fechas, es decir, 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 el parámetro f_{iso} del producto MCD43A1 para la clasificación.

2.2. Áreas verdad terreno

La aplicación de una clasificación supervisada requiere, además, 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: matorral ralo, matorral denso/medio, bosque coníferas, bosque frondosas, regadío cítrico, regadío mosaico, secano olivo, secano vid, secano mosaico, cereal/barbecho, arrozal, urbano, y superficies acuosas (ver [figura 2](#)).

A continuación, elegimos diversos polígonos pertenecientes a cada clase de los que disponíamos de información de campo, con lo que podemos tener certeza de su autenticidad, 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 ello podemos comprobar a priori la capacidad de discriminación entre clases. 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, por ejemplo, en la [figura 3b](#) son muy similares, lo que indica que la discriminación entre ellas no es tan sencilla, al menos con el uso de esta información espectral. Tomando como referencia este criterio las clases pueden redefinirse para optimizar los resultados.

Posteriormente, tomando los polígonos seleccionados para cada clase como áreas de referencia o entrenamiento, aplicamos la clasificación supervisada (con una probabilidad límite de 0.95) sobre las imágenes f_{iso} de las bandas 1 a 7 de MODIS, descartando para ello los píxeles donde el producto asociado MCD43A2, que contiene información sobre la bondad del producto MCD43A1, no indique una calidad óptima.

2.3. Parámetros asociados a la vegetación

Finalmente, de forma adicional, se generaron bandas con el Índice Diferencial de Vegetación Normalizado (NDVI, Deering, 1978) y con los parámetros f_{geo} y f_{vol} de las bandas 1 (rojo) y 2 (infrarrojo cercano), respectivamente, del producto MCD43A1, con las que se define el índice SSI (Structural Scattering Index) (Gao *et al.*, 2003), relacionado con la estructura de la vegetación:

$$SSI = \ln \left(\frac{f_{vol,2}}{f_{geo,1}} \right) \quad (3)$$

Gao *et al.* (2003) definieron esta magnitud con el fin de distinguir superficies con valores similares de NDVI en función de la estructura vegetal, caracterizada por la relación entre los parámetros volumétrico y geométrico, tomando valores de SSI bajos para estructuras vegetales con fuertes efectos de sombras, como matorral ralo, abetos, maíz, etc., y más elevados para el resto de estructuras. En este trabajo se tomó este parámetro con la finalidad de distinguir entre clases con firmas espectrales similares para el parámetro f_{iso} , como son los bosques de coníferas y de frondosas (ver [figura 3c](#)). La [figura 4](#) muestra, como ejemplo, los valores del NDVI y el SSI obtenidos para cada una de las clases inicialmente escogidas.

De nuevo se aplicó una clasificación supervisada con las áreas de entrenamiento sobre la combinación de bandas 1 a 7 del parámetro f_{iso} y el NDVI, o bien sobre las bandas 1 a 7 de f_{iso} y el SSI.

3. Resultados y precisión

Para estimar la precisión de una clasificación se calcula la matriz de error o matriz de confusión (Jensen, 1986), 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, P , que cuantifica el número de píxeles correctamente clasificados, b) la precisión del productor, P_p , que indica la probabilidad de que un píxel de la clase i está correctamente clasificado, y c) la precisión del usuario, P_u , que indica la probabilidad de que un píxel 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" respectivamente, es decir, los errores que cuantifican cuántos píxeles pertenecientes a la región de interés de la clase i no están clasificados como dicha clase y cuántos píxeles clasificados como clase i hay en las regiones de interés de clases diferentes a ésta. 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.

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. La [figura 5a](#) muestra la clasificación obtenida a partir de una imagen MCD43A1 de agosto de 2007 usando como regiones de interés todas las clases inicialmente seleccionadas y las bandas 1 a 7 del parámetro f_{iso} . 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 68% mientras que su precisión global, comprobada frente a áreas verdad terreno de validación, es del 55%. Además de evaluar los resultados de la clasificación realizada usando las bandas 1 a 7 del parámetro f_{iso} , también analizamos los resultados al añadir el NDVI o el SSI (Gao *et al.*, 2003) como una banda más, ambos generados a partir del mismo producto MCD43A1. La [figura 5b](#) y [figura 5c](#) muestran las clasificaciones obtenidas de este modo y la [tabla 3](#) y [tabla 4](#) los parámetros de precisión. Aunque los resultados dependen de las clases, mejoran ligeramente a nivel de precisiones globales con el uso de alguna de estas bandas adicionales.

Dada la relativamente baja precisión obtenida para la clasificación cuando usamos el total de las 13 clases inicialmente seleccionadas, y atendiendo a la capacidad de discriminación entre clases según su signatura espectral (ver [figura 3](#)), decidimos juntar las clases con mayor dificultad de discriminación (como por ejemplo bosque de coníferas y de frondosas en una misma clase), quedándonos finalmente con 9 clases: bosque, matorral, áreas urbanas, cereal/barbecho, seco (vid), seco (olivo), regadío, arrozales y agua. Esta claro que para ciertas aplicaciones el hecho de juntar clases podría ser poco conveniente, perdiendo la posibilidad de distinguir entre ciertos tipos de usos de suelos. Sin embargo, en función de sus requerimientos, el usuario deberá decidir si dar prioridad al número de clases o a la precisión final de la clasificación. Usando estas 9 clases como referencia se obtuvieron las clasificaciones mostradas en la [figura 6](#), de nuevo con las 3 combinaciones de bandas, es decir, bandas 1 a 7 del parámetro f_{iso} , éstas más el NDVI y éstas más el SSI. En la [tabla 5](#), [tabla 6](#) y [tabla 7](#) se muestran los parámetros de precisión correspondientes. De nuevo vemos que las precisiones aumentan ligeramente cuando añadimos parámetros de vegetación como el NDVI y el SSI, obteniéndose las mejores precisiones para la combinación de las bandas 1 a 7 más el NDVI, con una bondad de 79% para la fase de entrenamiento y una precisión del 70%, comprobada frente a áreas verdad terreno de validación. Estas precisiones son relativamente elevadas si consideramos que se trata de una clasificación realizada sobre imágenes de 500x500m² de píxel.

Finalmente, la [figura 7](#) presenta clasificaciones equivalentes a las mostradas en la [figura 6](#) pero usando como base una imagen MCD43A1 de un año posterior (agosto de 2008). En este caso, y para la combinación de bandas 1 a 7 del parámetro f_{iso} y el NDVI, obtenemos una bondad para la fase de entrenamiento del 75% y una precisión de validación del 68%. Estos resultados son similares a los obtenidos con la imagen de 2007, lo que otorga confianza a la metodología propuesta.

4. Conclusiones

En este trabajo proponemos un método para la generación periódica, cada 16 días si se desea, de mapas de tipos de superficies o usos de suelo a escala regional a partir de imágenes MCD43A1 de MODIS. Para ello se propone tomar como base polígonos de la base CORINE, contrastados frente a información terreno y ortofotos, y el uso del parámetro isótropo del modelo BRDF proporcionado por el producto MCD43A1, ya que de este modo los mapas resultantes serían lo más comparables posible. El uso adicional de parámetros asociados a la vegetación, como el NDVI o el índice estructural SSI mejora, aunque muy ligeramente, la precisión de las clasificaciones obtenidas. El análisis de las matrices de confusión asociadas a estas clasificaciones demuestra que se obtendrían con una precisión relativamente elevada. Los mapas obtenidos con esta metodología son útiles para caracterizar las coberturas terrestres, lo cual es necesario para la determinación de otras variables físicas superficiales y para cualquier estudio que conlleve un conocimiento de las interacciones atmósfera-superficie.

Referencias bibliográficas

- CEC (Commission of the European Communities) (1995): *CORINE Land Cover Technique Guide*, 163 p.
- Deering, D.W. (1978): *Rangeland reflectance characteristics measured by aircraft and spacecraft sensors*. Ph.D. Diss. Texas A&M Univ., College Station, 338 p.
- Gao, F., Schaaf, C.B., Strahler, A.H., Jin, Y., y Li, X. (2003): "Detecting vegetation structure using a kernel-based BRDF model", *Remote Sensing of Environment*, 86, pp. 189-205.
- Jensen, J.R. (1986): *Introductory Digital Image Processing*. New Jersey, Prentice-Hall, 379 p.
- Lucht, W. (1998): "Expected retrieval accuracies of bidirectional reflectance and albedo from EOS-MODIS and MISR angular sampling", *Journal of Geophysical Research*, 103, pp. 8763-8778.
- Verger, A., Camacho-de Coca, F., y Meliá, J. (2005): "Revisión de los modelos paramétricos de BRDF", *Revista de Teledetección*, 23, pp. 65-80.
- Richards, J.A. (1999): *Remote Sensing Digital Image Analysis*. Berlin, Springer-Verlag, 240 p.
- Roujean, 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", *Journal of Geophysical Research*, 97, pp. 20455-20468.
- Strahler, A.H., Muller, J.P., y MODIS Science Team Members (1999): *MODIS BRDF/Albedo Product. Algorithm Theoretical Basis Document (ATBD)*. Disponible en: <http://modis.gsfc.nasa.gov>.

Agradecimientos

Queremos agradecer la apreciable colaboración del Dr. J. A. Alloza. Este estudio ha sido financiado por el Ministerio de Ciencia e Innovación 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, el cual está cofinanciado por el Fondo Social Europeo. La

fundación CEAM está también financiada por la Generalitat Valenciana y BANCAIXA.

TABLAS

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	$\kappa = \frac{N \sum_{i=1}^m x_{ii} - \sum_{i=1}^m x_{i\Sigma} x_{\Sigma i}}{N^2 - \sum_{i=1}^m x_{i\Sigma} x_{\Sigma i}}$
<p>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. $x_{i\Sigma}$ = suma de los píxeles clasificados como la clase i.</p>	

Tabla 2. Precisión de la clasificación mostrada en la [Figura 5a](#), realizada con todas las clases inicialmente seleccionadas y las combinaciones de bandas 1 a 7 del parámetro f_{iso} .

	Entrenamiento		Validación	
	P_p (%)	P_u (%)	P_p (%)	P_u (%)
Bosque/Coníferas	72	78	50	44
Bosque/Frondosas	92	46	92	44
Matorral/Denso-medio	68	75	62	83
Matorral/Ralo	64	35	50	44
Urbano	84	49	81	89
Cereal/Barbecho	80	34	75	74
Secano/Mosaico	49	77	8	7
Secano/Vid	81	86	33	34
Secano/Olivo	74	40	27	26
Regadío/Mosaico	48	56	29	31
Regadío/Cítrico	77	78	78	81
Arrozal	94	87	97	100
Coeficiente Kappa	0,63		0,49	
Precisión global (%)	68		55	

Tabla 3. Precisión de la clasificación mostrada en la [Figura 5b](#), realizada con todas las clases inicialmente seleccionadas y las combinaciones de bandas 1 a 7 de f_{iso} y NDVI.

	Entrenamiento		Validación	
	$P_p(\%)$	$P_u(\%)$	$P_p(\%)$	$P_u(\%)$
Bosque/Coníferas	64	84	42	50
Bosque/Frondosas	94	37	91	37
Matorral/Denso-medio	75	70	68	85
Matorral/Ralo	58	60	43	48
Urbano	86	49	81	90
Cereal/Barbecho	80	31	75	73
Secano/Mosaico	48	76	7	6
Secano/Vid	84	84	39	38
Secano/Olivo	77	37	30	27
Regadío/Mosaico	40	66	19	33
Regadío/Cítrico	81	75	85	77
Arrozal	95	90	97	100
Coefficiente Kappa	0,63		0,50	
Precisión global (%)	67		56	

Tabla 4. Precisión de la clasificación mostrada en la [Figura 5c](#), realizada con todas las clases inicialmente seleccionadas y las combinaciones de bandas 1 a 7 de f_{iso} y SSI.

	Entrenamiento		Validación	
	$P_p(\%)$	$P_u(\%)$	$P_p(\%)$	$P_u(\%)$
Bosque/Coníferas	73	80	45	41
Bosque/Frondosas	92	45	91	43
Matorral/Denso-medio	70	76	61	82
Matorral/Ralo	67	38	41	41
Urbano	83	50	80	89
Cereal/Barbecho	78	35	72	74
Secano/Mosaico	50	79	9	7
Secano/Vid	82	86	44	45
Secano/Olivo	79	48	38	32
Regadío/Mosaico	54	59	30	40
Regadío/Cítrico	77	78	75	85
Arrozal	95	88	97	97
Coefficiente Kappa	0,65		0,50	
Precisión global (%)	69		55	

Tabla 5. Precisión de la clasificación mostrada en la [Figura 6a](#), realizada con las clases finalmente seleccionadas y las combinaciones de bandas 1 a 7 del parámetro f_{iso} .

	Entrenamiento		Validación	
	$P_p(\%)$	$P_u(\%)$	$P_p(\%)$	$P_u(\%)$
Bosque	80	74	70	40
Matorral	70	81	62	88
Urbano	90	61	83	81
Cereal/Barbecho	87	43	82	69
Secano/Vid	85	96	51	45
Secano/Olivo	84	61	54	65
Regadío	83	91	86	77
Arrozal	94	87	97	100
Coefficiente Kappa	0,72		0,64	
Precisión global (%)	78		70	

Tabla 6. Precisión de la clasificación mostrada en la [Figura 6b](#), realizada con las clases finalmente seleccionadas y las combinaciones de bandas 1 a 7 de f_{iso} y NDVI.

	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
Regadío	84	91	88	79
Arrozal	96	90	97	100
Coefficiente Kappa	0,73		0,64	
Precisión global (%)	79		70	

Tabla 7. Precisión de la clasificación mostrada en la [Figura 6c](#), realizada con las clases finalmente seleccionadas y las combinaciones de bandas 1 a 7 de f_{iso} y SSI.

	Entrenamiento		Validación	
	$P_p(\%)$	$P_u(\%)$	$P_p(\%)$	$P_u(\%)$
Bosque	80	75	65	40
Matorral	71	82	61	89
Urbano	88	62	81	79
Cereal/Barbecho	87	44	81	69
Secano/Vid	86	96	61	51
Secano/Olivo	85	63	53	65
Regadío	84	92	89	78
Arrozal	95	88	97	97
Coefficiente Kappa	0,73		0,64	
Precisión global (%)	79		69	

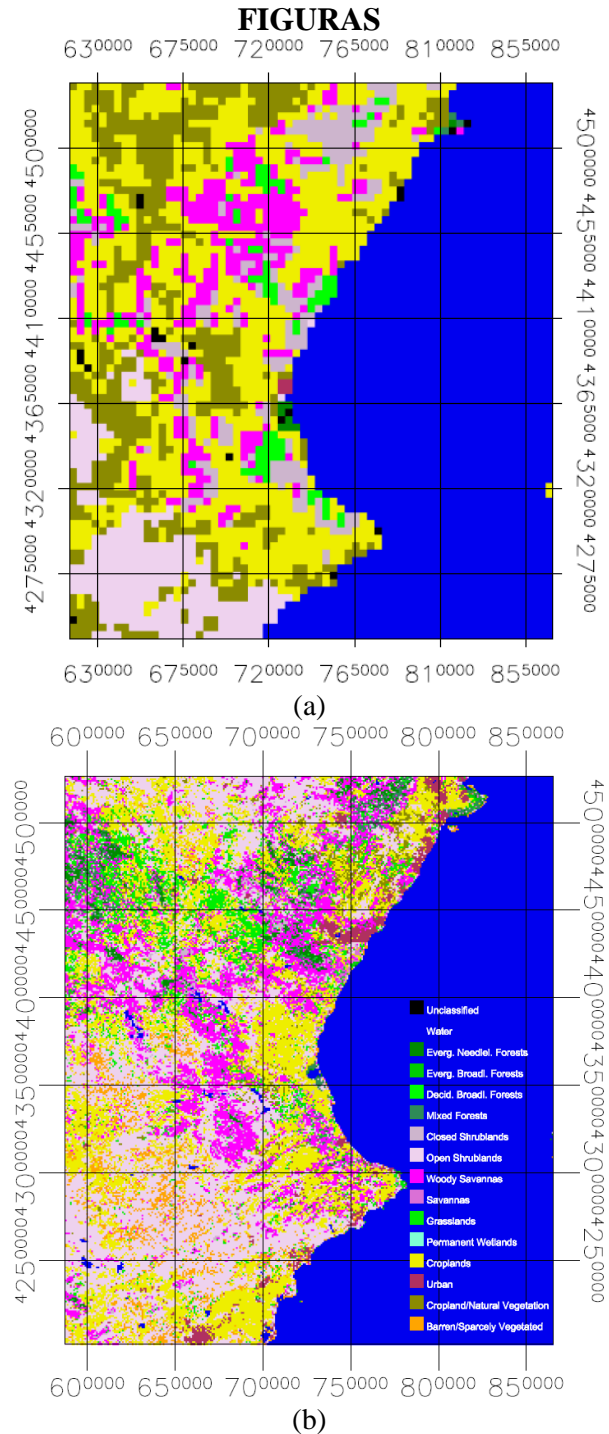


Figura 1. Recortes de los productos (a) LSASAF y (b) MOD12Q1 para la Comunidad Valenciana (Proyección UTM, European mean 1950, Uso 30N).




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

Nicòs Corts, R. et al. (2010): "Clasificación periódica de coberturas terrestres a escala regional con imágenes MODIS", *GeoFocus (Artículos)*, nº 10, p. 1-17. ISSN: 1578-5157

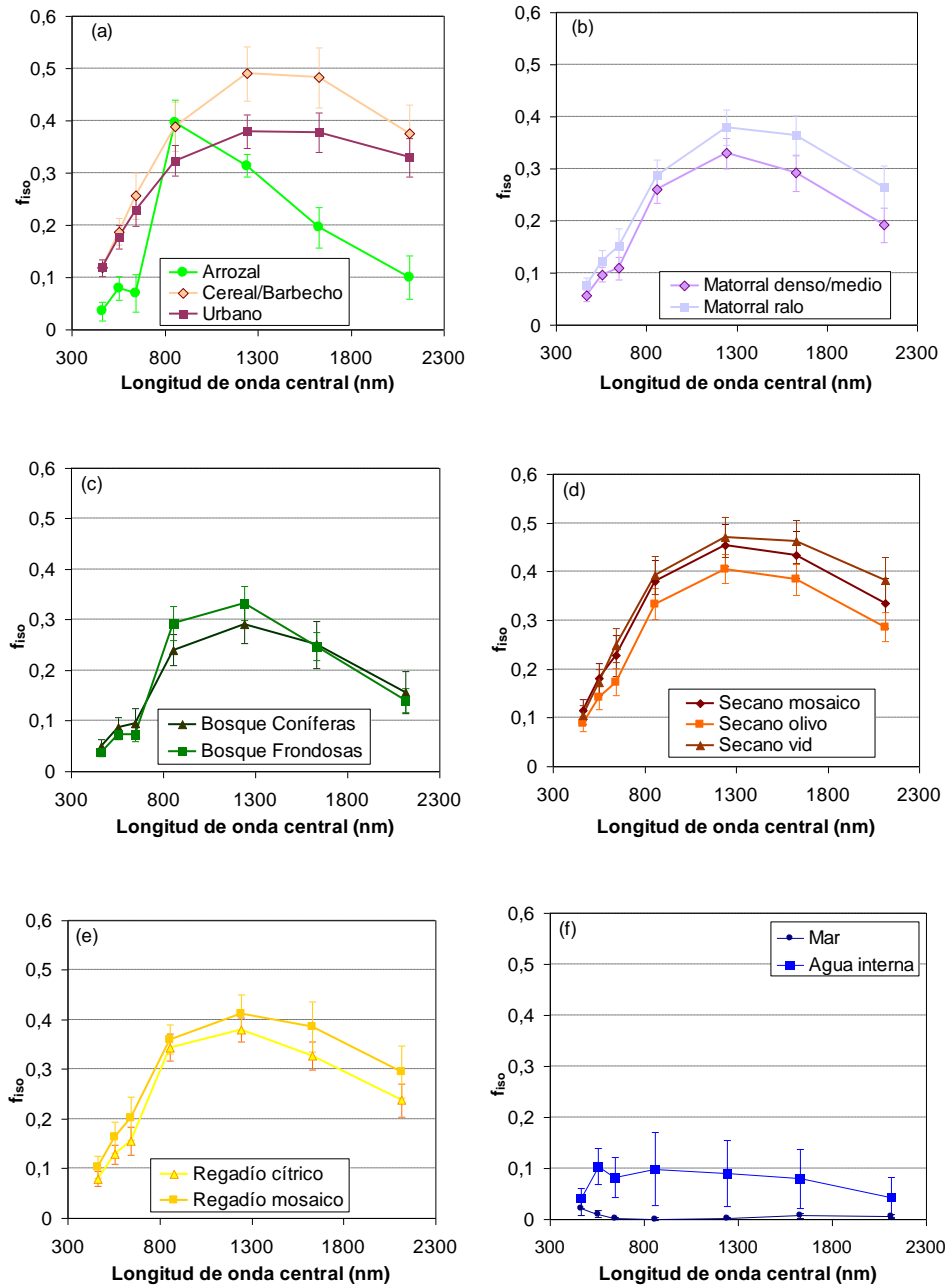


Figura 3. Variación del parámetro f_{150} con las bandas MODIS.

Nicòs Corts, R. et al. (2010): "Clasificación periódica de coberturas terrestres a escala regional con imágenes MODIS", *GeoFocus (Artículos)*, nº 10, p. 1-17. ISSN: 1578-5157




Figura 4. NDVI y SSI para cada una de las clases iniciales (agosto 2007).

Niclos Corts, R. et al. (2010): "Clasificación periódica de coberturas terrestres a escala regional con imágenes MODIS", *GeoFocus (Artículos)*, nº 10, p. 1-17. ISSN: 1578-5157

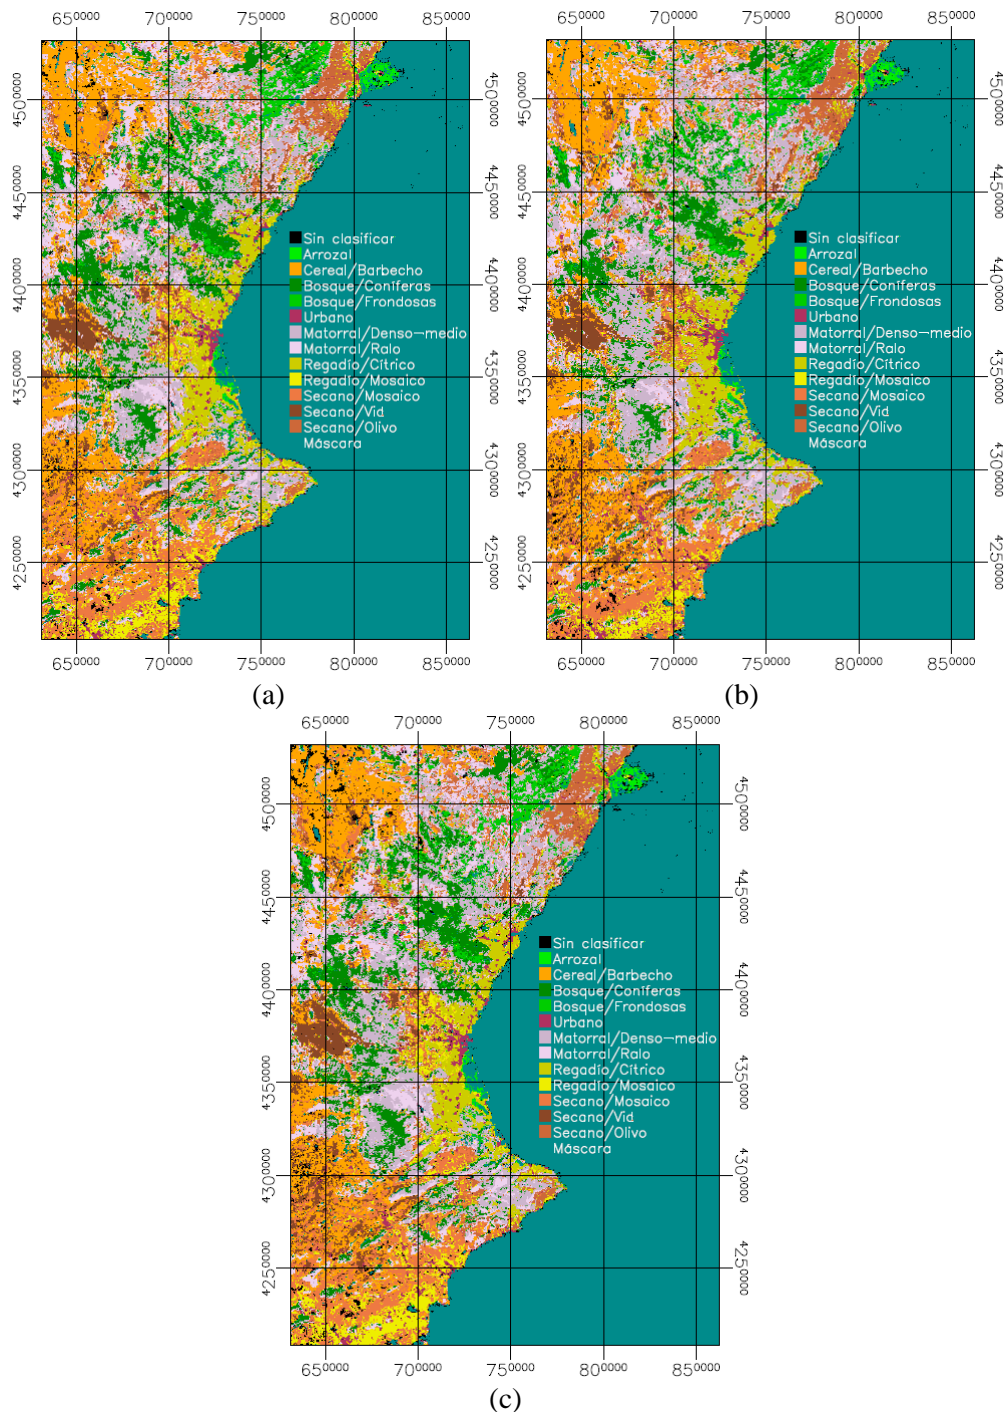


Figura 5. Ejemplo de clasificación con todas las clases seleccionadas inicialmente para agosto de 2007. (a) bandas 1-7 de f_{180} , (b) bandas 1-7 de f_{180} y NDVI, y (c) bandas 1-7 de f_{180} y SSL. Proyección UTM, European mean 1950, Uso 30N.

Nicòs Corts, R. et al. (2010): "Clasificación periódica de coberturas terrestres a escala regional con imágenes MODIS", *GeoFocus (Artículos)*, nº 10, p. 1-17. ISSN: 1578-5157

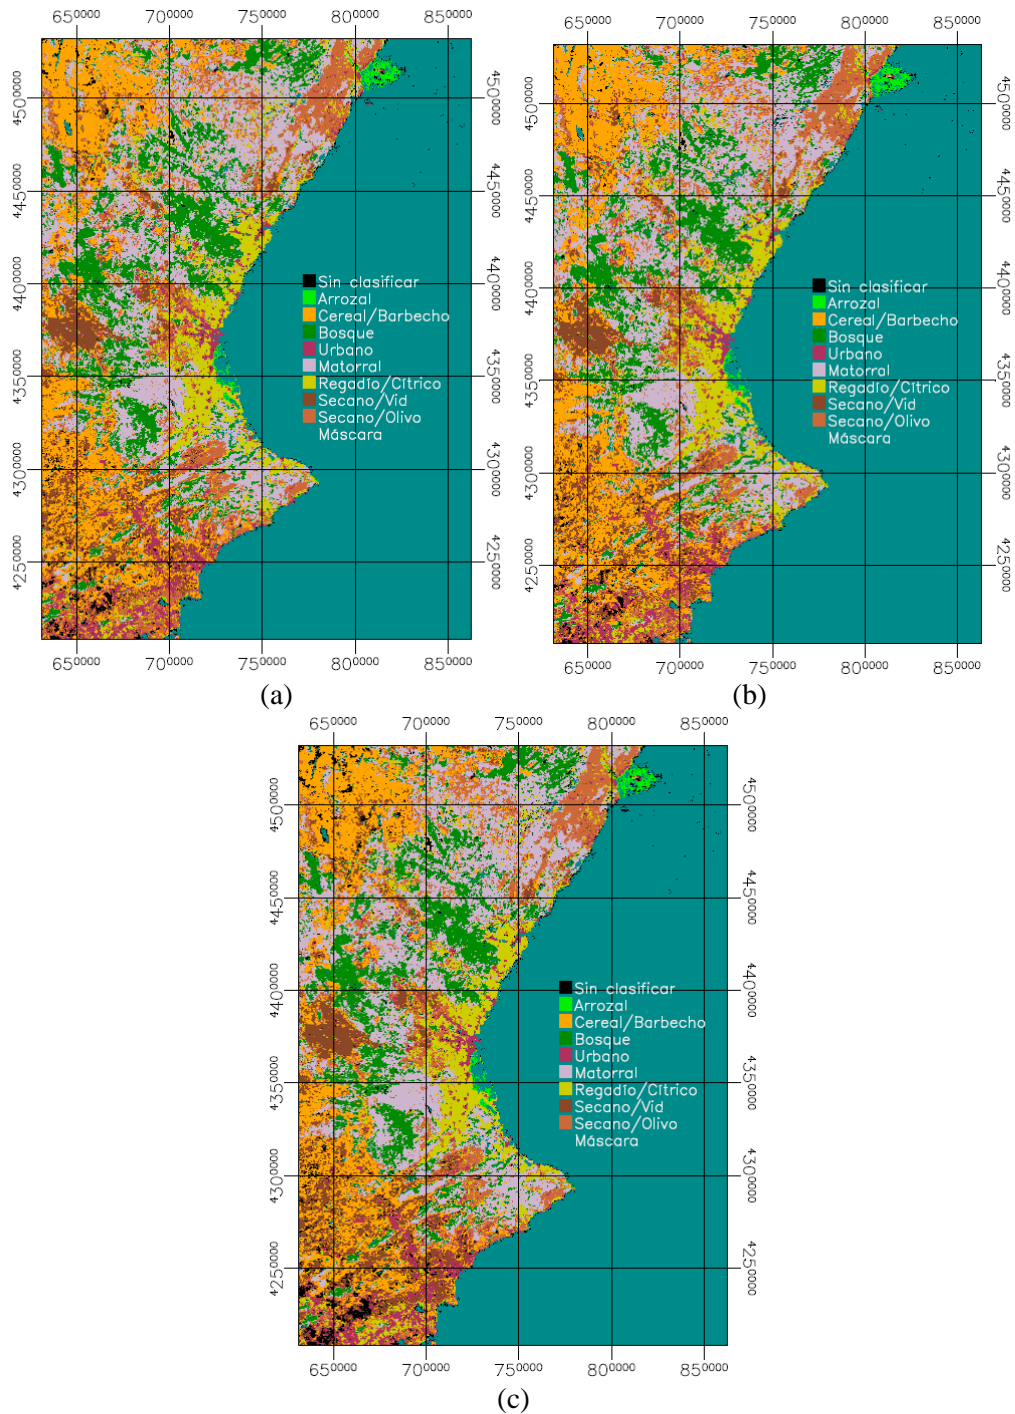


Figura 6. Ejemplo de clasificación con las clases finalmente seleccionadas para agosto de 2007. (a) bandas 1-7 de f_{150} , (b) bandas 1-7 de f_{150} y NDVI, y (c) bandas 1-7 de f_{150} y SSI.

Nicòs Corts, R. et al. (2010): "Clasificación periódica de coberturas terrestres a escala regional con imágenes MODIS", *GeoFocus (Artículos)*, nº 10, p. 1-17. ISSN: 1578-5157

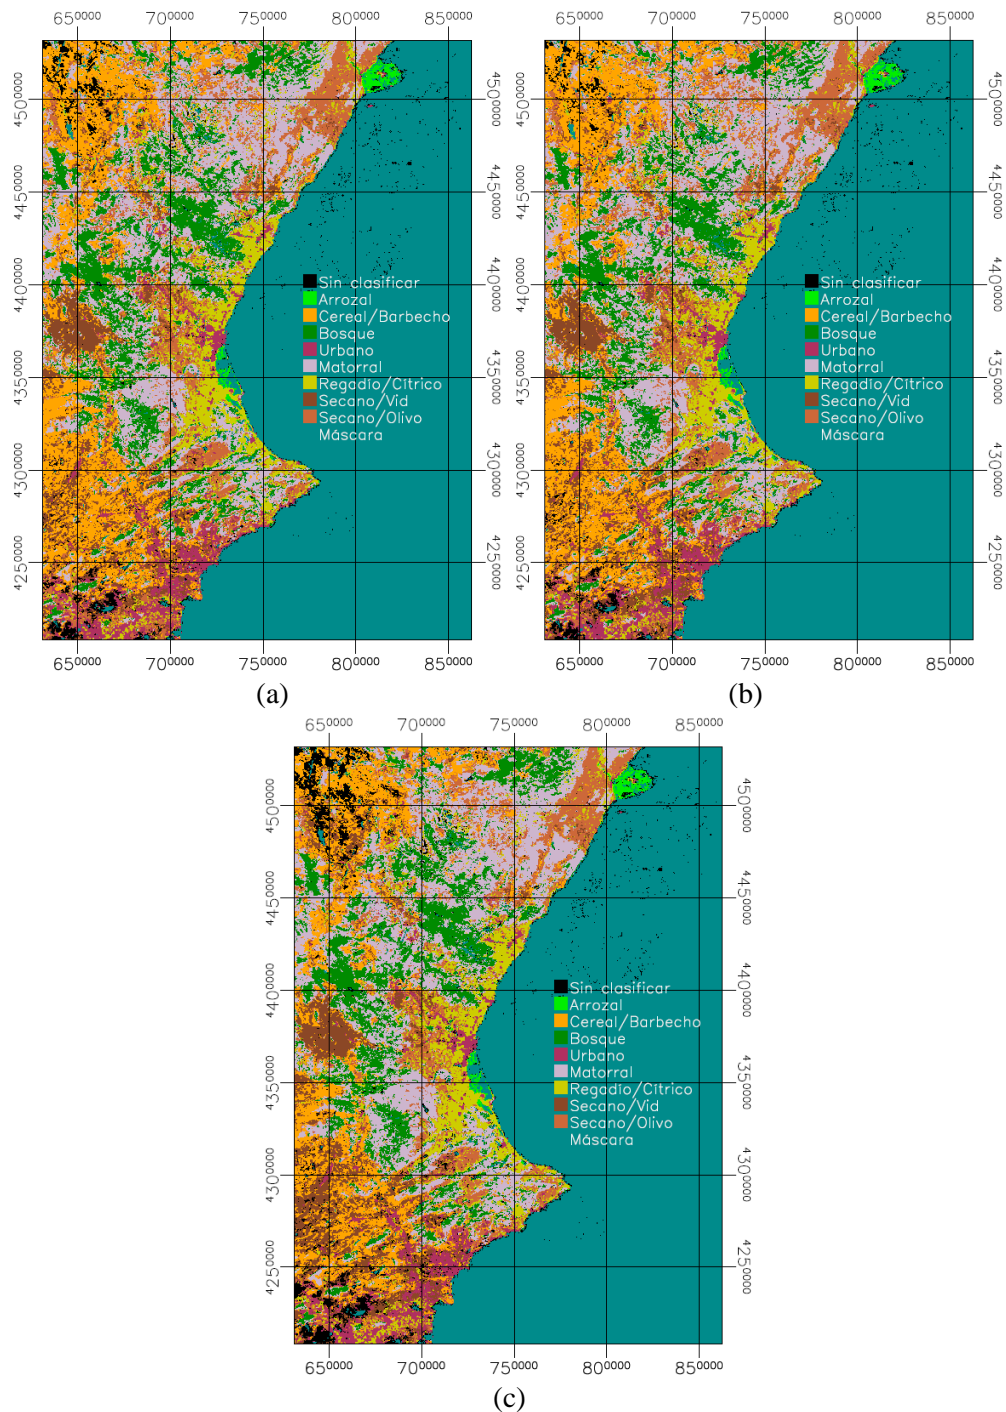


Figura 7. Ejemplo de clasificación con las clases finalmente seleccionadas para agosto de 2008. (a) bandas 1-7 de f_{iso} , (b) bandas 1-7 de f_{iso} y NDVI, y (c) bandas 1-7 de f_{iso} y SSI.