

Distribución espacial de la incertidumbre en mapas de cubiertas obtenidos mediante teledetección

Pons, X.^{*1}, Sevillano, E.², Moré, G.², Serra, P.², Cornford, D.³, Ninyerola, M.⁴

¹ *Grumets Research Group, Dep. de Geografia. Edifici B. Universitat Autònoma de Barcelona. E-08193 Bellaterra, Barcelona, España.*

² *Grumets Research Group, CREA. Edifici C. Campus de la UAB. E-08193 Bellaterra, Barcelona, España.*

³ *Computer Science, Aston University. Birmingham, United Kingdom.*

⁴ *Grumets Research Group, Dep. Biologia Animal, Vegetal i Ecologia. Edifici C. Universitat Autònoma de Barcelona. E-08193 Bellaterra, Barcelona, España.*

Resumen: La utilización conjunta de imágenes de teledetección con clasificadores estadísticos con la finalidad de obtener cartografía temática de tipo categórico no suele proporcionar datos acerca de cómo se distribuye espacialmente el error y la incertidumbre en los mapas resultantes. Este trabajo expone, en el contexto del proyecto FP7 GeoViQua, aproximaciones posibilistas para métodos en pasos sucesivos como los clasificadores híbridos. Tanto en el caso de estrategias "por píxel" como "por objeto", la propuesta se basa en la utilización de la verdad terreno disponible para modelizar adecuadamente la distribución espacial de los errores. Los resultados permiten confeccionar mapas de acierto de la clasificación con un muy elevado nivel de fiabilidad ($R^2 > 0,94$), con lo cual los usuarios de los mapas conocen con confianza la exactitud en cada zona de los mismos.

Palabras clave: clasificación híbrida, distribución espacial de la incertidumbre y del error, Landsat, regresión logística multivariante, regresión lineal multivariante.

Spatial distribution of the uncertainty in land cover maps obtained from remote sensing

Abstract: When combining remote sensing imagery with statistical classifiers to obtain categorical thematic maps it is not usual to provide data about the spatial distribution of the error and uncertainty of the resulting maps. This paper describes, in the context of GeoViQua FP7 project, feasible approaches for methods based on several steps such as hybrid classifiers. Both for "per pixel" and "per polygon" strategies, the proposal is based on the use of the available ground truth, which is used to properly model the spatial distribution of the errors. Results allow mapping the classification success with a very high level of reliability ($R^2 > 0,94$), providing users a sound knowledge of the accuracy at every area of the map.

Key words: hybrid classification, spatial distribution of uncertainty and error, Landsat, multivariate logistic regression, multivariate linear regression.

1. Introducción

La combinación de imágenes de teledetección con clasificadores estadísticos para obtener cartografía temática de tipo categórico (mapas de cubiertas

del suelo, discriminación de superficies quemadas, etc.) es hoy en día una práctica frecuente y, como en muchas otras áreas en que se genera nueva información geográfica, el conocimiento de la calidad de los mapas producidos es esencial

* Autor para la correspondencia: Xavier.Pons@uab.cat

(Foody, 2009). Sin embargo, y a pesar de que en percepción remota existe una consolidada tradición de informar sobre dicha calidad a partir de indicadores globales (acierto global, índice *kappa*, etc.), la información sobre la distribución espacial de los errores es prácticamente inexistente. Este hecho contrasta con la cada vez más necesaria disponibilidad de estos datos para llevar a cabo con rigor desde la simple consulta del mapa hasta su amplio abanico de aplicaciones en planificación territorial, modelización numérica, etc.

Probablemente esta ausencia de información acerca de la espacialización de la exactitud temática sea debida, en parte, a la falta de investigación sobre cómo obtenerla, visualizarla adecuadamente, etc., por lo que proyectos de investigación, como el FP7 GeoViQua, pretenden realizar aportaciones en este ámbito. En este contexto, el presente trabajo expondrá algunos avances en la distribución espacial del error en la cartografía categórica generada por teledetección.

Si bien algunos clasificadores, como los de máxima verosimilitud, permiten la estimación y representación espacial de la incertidumbre a través de una aproximación probabilística a nivel del objeto que es clasificado (sea este un píxel o un polígono resultado de segmentación de la imagen), la cuantificación de la relación entre dicho estimador y el error en cada punto del mapa merece algo más de atención. En efecto, aunque podamos aplicar (por ejemplo con la Ecuación 1) una medida de incertidumbre en muchos clasificadores (por ejemplo tomando las diferentes distancias estadísticas en un clasificador de mínima distancia), para la mayoría de métodos de clasificación no existen estimadores directos de la probabilidad de acierto en cada píxel, o en cada polígono de una aproximación basada en objetos.

Nuestro objetivo es, pues, investigar en la obtención de métodos que sean generales (no sólo aplicables a escenarios concretos) a fin de poder dar a conocer la distribución espacial de la exactitud en los mapas categóricos generados mediante métodos de clasificación aplicados a imágenes de teledetección. En particular, la constatación del hecho de que, independientemente del método de clasificación aplicado, casi siempre exista una verdad terreno disponible (típicamente necesaria para el entrenamiento del clasificador y/o para el cálculo

de la exactitud global del mapa resultante), parece un interesante filón para nuestro propósito.

Este estudio está orientado hacia el desarrollo de un protocolo de espacialización del error en un marco genérico basado en los parámetros del clasificador y los datos de referencia de la verdad terreno. Se presentará el método en el ámbito de las clasificaciones híbridas (Moré et al., 2006; Serra et al., 2009), que combinan fases no supervisadas con fases supervisadas, y también analizándolo desde el punto de vista de una visión “por píxel” como desde una visión “por objetos”. En la cartografía resultante, el conocimiento de la distribución de la incertidumbre muy necesario, aunque sea poco inmediata su obtención, dada la naturaleza compleja del método de clasificación. Los avances obtenidos se han realizado, como se detallará, en un ámbito geográfico extenso (una escena Landsat completa con imágenes captadas por el sensor TM), con numerosas variables adicionales (climatológicas, etc) que contribuyen a mejorar la clasificación, y en un escenario robusto, caracterizado por una amplia disponibilidad de verdad terreno, lo que ha permitido la validación independiente de los métodos propuestos. Naturalmente, en otros experimentos puede comprobarse la bondad de la aproximación aquí ensayada utilizando otros clasificadores como el de las *k*-medias, máxima probabilidad o *Random Forests*, por citar algunos.

2. Área de estudio

Nuestro interés en conseguir resultados generales o, como mínimo, no ceñidos a una pequeña muestra de algunos miles de píxeles, nos llevó a tomar como área de estudio una escena Landsat completa, en este caso la 197-031 del *World Reference System (WRS) 2*, que viene siendo utilizado desde el lanzamiento del satélite Landsat 4; dicha escena está situada en el NE de la Península Ibérica, cubriendo una buena parte de Cataluña, alrededor de 12000 km², el 37% del territorio (Figura 1). Si bien es cierto que dicha escena contiene una parte importante de mar, también lo es que, por su especial orografía, su historia humana, etc., presenta una gran diversidad de cubiertas del suelo, lo que la convierte en un complejo banco de pruebas, especialmente interesante para los propósitos de este estudio.

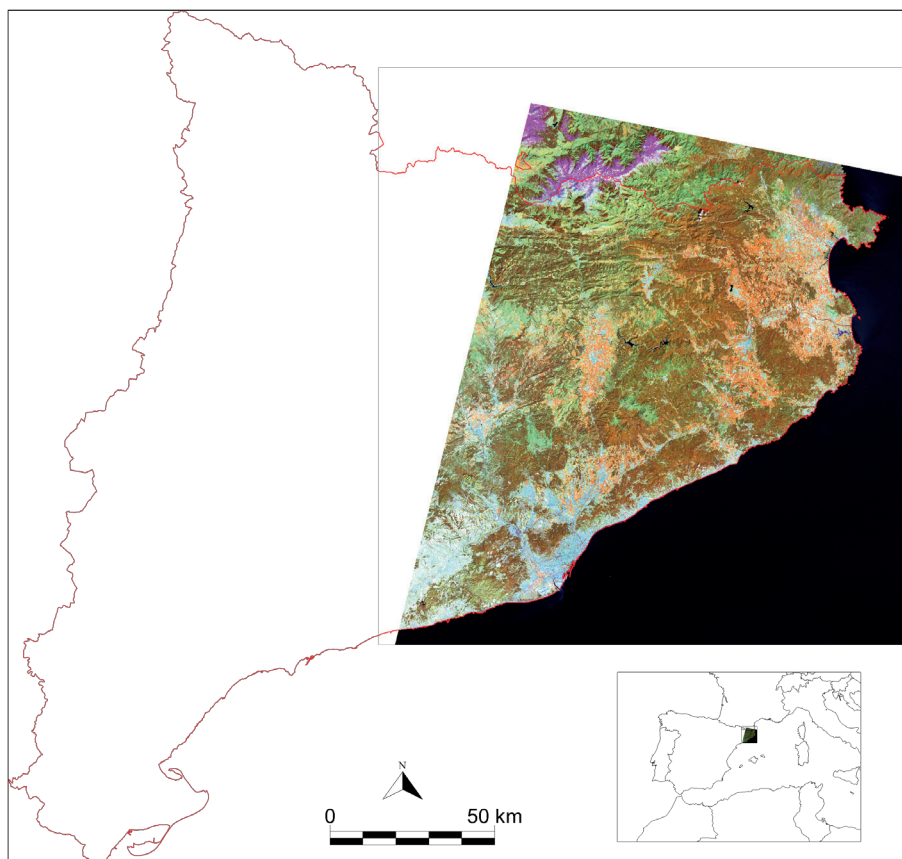


Figura 1. Área de estudio, localizada en el nordeste de Cataluña, en que puede apreciarse una de las imágenes Landsat utilizadas.

3. Materiales y métodos

Dada la existencia, para el área de estudio, de un detallado mapa de cubiertas del suelo en 2006 (CREAF, 2007) que podía ser usado como verdad terreno de forma territorialmente exhaustiva, éste fue considerado óptimo para nuestros propósitos. Dado nuestro interés en avanzar hacia una metodología lo más general posible, evitar el eventual sesgo derivado de unas áreas de verdad terreno que no fueran perfectamente representativas de la “verdad” nos pareció el mejor escenario.

A continuación se detalla qué imágenes remotas y métodos de clasificación se emplearon, los principales procesos a que fue sometido el mapa que proporcionó las áreas de entrenamiento y de test, etc. Para la mayoría de estos procesos se utilizó el software de Teledetección y SIG MiraMon (Pons, 2004), excepto para los procesos de regresión logística, en que se utilizó SPSS (Norušis, 2002).

3.1. Imágenes y su procesado. Variables derivadas y complementarias

Para la obtención por clasificación del mapa en el que deseamos estudiar la distribución espacial de su incertidumbre utilizamos las bandas del espectro solar (30 m de resolución espacial) de una serie temporal de imágenes Landsat TM. La serie estaba compuesta por seis fechas entre marzo y septiembre para poder cubrir un amplio abanico de condiciones fenológicas al tiempo que para evitar excesivas sombras invernales. La existencia de una cobertura nubosa más o menos importante en algunos meses de 2006 comportó la elección de escenas del año anterior y posterior, suponiendo que la dinámica de cambios interanuales había sido pequeña. Las fechas concretas utilizadas fueron las siguientes: 09/03/2005, 26/04/2005, 18/05/2007, 29/06/2005, 02/07/2006, 04/09/2006.

El procesado de las imágenes incluyó correcciones geométricas para las que se empleó un modelo digital de elevaciones (MDE) y se aplicaron, también, máscaras de nubes y sus sombras, mar y nieve. Las correcciones geométricas se realizaron a través del método Palà y Pons (1995) y Pons *et al.* (2010) basado en centenares de puntos de control obtenidos automáticamente en todo el rango planimétrico y altimétrico, con lo que se garantiza una gran robustez en el ajuste. Los puntos de control se localizan con un algoritmo adecuado en ortofotografías de referencia producidas por el Institut Cartogràfic de Catalunya, de 0,5 m de resolución espacial; el 50% de los puntos son usados para el ajuste del modelo y el 50% para test. Con este método se obtienen errores RMS inferiores a 1/3 de píxel, con lo que se asegura que en la serie multitemporal no se presenten incoherencias que constituyan desplazamientos de 1 píxel o más, aspecto importante para evitar confusiones espectrales resultantes de pequeños movimientos geométricos. Por lo que respecta a las correcciones radiométricas, éstas se realizaron con el objetivo de convertir los valores digitales a valores de reflectancia efectuando una corrección atmosférica y topográfica (Pons y Solé-Sugrañes, 1994, Pons *et al.*, 2014). El método utiliza áreas pseudoinvariantes para proporcionar mayor robustez a la serie temporal a la vez que hacerla coherente con otras series de referencia como MODIS.

Una vez corregidas las imágenes originales, como variables adicionales se incluyeron el índice de vegetación de diferencia normalizada (NDVI) (Rouse *et al.*, 1973) para todas las fechas de la serie temporal, y se añadieron variables topoclimáticas calculadas a partir del MDE y de la serie histórica del Atlas Climático Digital de Cataluña (Ninyerola *et al.*, 2000; Pons y Ninyerola, 2008): pendientes topográficas, temperatura mínima de los tres meses más fríos, temperatura máxima de los tres meses más cálidos, precipitación limitante mínima de los tres meses con menos lluvias y radiación solar mínima de los tres meses con menor radiación. En el caso de la pendiente, ésta se derivó del MDE calculado a partir de los datos LiDAR del Plan Nacional de Ortofotografía Aérea, PNOA, de 5 m de resolución planimétrica, del año 2010. La introducción de estas variables adicionales contribuye a discriminar mejor algunas categorías temáticas que podrían confundirse únicamente empleando la serie temporal de Landsat (Moré *et al.*, 2006). Con

ello se obtuvieron 47 variables independientes para alimentar la clasificación, las cuales fueron previamente estandarizadas mediante la resta de la media y la división entre la desviación estándar de cada una de ellas.

3.2. Verdad terreno (MCSC)

El mapa de cubiertas del suelo de Cataluña del año 2006, MCSC, fue creado por fotointerpretación de ortofotografías 2005-2007 de 0,5 m de resolución (Burriel *et al.*, 2005). Su elevado detalle espacial y leyenda, así como su carácter territorialmente completo, han permitido en este trabajo su uso para propósitos de entrenamiento, para test y para validación, en condiciones libres de sesgo. En efecto, trabajar con prácticamente toda la población estadística en lugar de con una muestra permite acometer de forma robusta nuestros propósitos (Foody, 2009).

La leyenda del MCSC fue adecuadamente simplificada a 12 categorías de acuerdo con los objetivos y posibilidades de las técnicas de clasificación digital utilizadas. La dimensión de píxel también fue adaptada a la resolución espacial de las imágenes de satélite utilizando una asignación categórica basada en un criterio de moda. Además, y para evitar grandes polígonos que hubieran sido poco realistas en nuestro experimento, se realizó una partición del espacio en base a una malla de 1 km×1 km de manera que ningún grupo contiguo de celdas del MCSC superara dicho tamaño. Finalmente, y también para simular de forma realista el procedimiento habitual de toma de áreas de entrenamiento y test, en que se evitan los bordes entre categorías para no introducir ruido adicional, se eliminó un *buffer* de anchura un píxel alrededor de todos los bordes de los polígonos originales reclasificados.

Una vez se dispuso de una base temporal y espacial razonablemente coherente con nuestras imágenes de teledetección, la dividimos en tres subconjuntos: de entrenamiento (de los clasificadores), de test (de las clasificaciones) y de validación (de los propios mapas de error). Para ello se realizó una selección aleatoria en que se impuso que quedaran representadas todas las categorías dentro de cada subconjunto, a la vez que para el subconjunto de entrenamiento se destinaba el 50% de la superficie

del MCSC, el 25% para áreas de test y el 25% restante para validación de los modelos de error.

3.3. Procesos de clasificación

En este trabajo hemos explorado la aproximación a la obtención de mapas categóricos a través de proceso digital de imágenes en teledetección por clasificación híbrida (Serra y Pons, 2008; Pons y Arcalís, 2012). La clasificación híbrida consiste en una clasificación no supervisada en que se solicita un elevado número (varios centenares, o incluso miles) de clases estadísticas (*clusters*), seguida de un proceso de asignación de dichas clases estadísticas a clases informacionales (de usuario) a través de la correspondencia espacial que explican las áreas de entrenamiento. Entre sus principales ventajas destacan la robustez estadística de las clases obtenidas y el soporte natural a categorías de usuario formadas por varias clases estadísticas. En la fase de clasificación no supervisada se solicitaron, aprovechando la flexibilidad de criterios de la implementación IsoData de MiraMon, 50 *clusters* en la diagonal multivariante y 2397 en muestreo sistemático con una distancia determinada entre muestras (3,5 km en nuestro experimento) sobre las áreas de datos de la imagen; el muestreo sistemático es especialmente en espacios estadísticos de tan alta dimensionalidad (47 variables) eficiente para encontrar semillas iniciales con posibilidades de generar *clusters*. Aunque en la clasificación híbrida las áreas de entrenamiento no se utilizarán hasta la segunda fase (que pone en relación las clases estadísticas y las categorías temáticas), es posible utilizarlas para muestrear semillas en su interior, garantizando así el hallazgo de clases estadísticas especialmente útiles para describir las categorías temáticas. Adicionalmente, se fijó el parámetro de tolerancia a sinvalores (NODATA) de forma que se permitiera la clasificación de un píxel si contenía como mínimo las variables topoclimáticas y una fecha de la serie de Landsat (en otras palabras, sólo se rechazaba un píxel si no contenía datos radiométricos para ninguna de las fechas).

En la fase no supervisada se indicó, además de la utilización de distancia euclidiana, que el mínimo número de píxeles en un *cluster* fuera de 5000 y que la mínima similitud entre clases por banda fuera del 1%. Nótese que el número mínimo de píxeles en un *cluster* se relaciona con

la representatividad, ya que si se toleran *clusters* muy pequeños es fácil que, aunque tengan valores de fidelidad altos, no sean utilizados para clasificar puesto que no puedan ser suficientemente representativos (véase el siguiente párrafo). El número de clases final obtenidas, tras las correspondientes iteraciones, fue de 577.

El principal criterio de la clasificación, además del número de clases estadísticas iniciales y la forma de establecerlas, y del número y definición de las categorías temáticas, son la fidelidad (F) y la representatividad (R), descritos en Moré *et al.* (2006). Brevemente, la fidelidad, F, consiste en la proporción umbral a través de la cual una clase estadística (definida por sus características espectrales, climáticas, etc.) está incluida como parte de una categoría temática. Por ejemplo, 0,8 equivale a que el 80% o más de la superficie de la clase estadística se encuentra incluida en un área de entrenamiento de una determinada categoría temática. Cuando esta situación se produce, la clase estadística será asignada a la categoría temática. Por su lado, R es la representatividad, de la clase estadística en la clase informacional, o sea la mínima proporción que una clase estadística debe constituir de una clase informacional para formar parte de ella. Así, cuando un píxel es clasificado, el programa lo asigna a la categoría temática más razonable debido a la elevada correspondencia entre la clase estadística y el área de entrenamiento, a la vez que garantiza que la clase estadística consigue constituir una proporción suficiente de la categoría temática. En el caso de que una clase estadística no contenga una proporción umbral significativa (por ejemplo, una F de sólo el 10%) o que equivalga a una superficie ínfima de una categoría temática (R nos informe que es prácticamente equivalente a ruido), el resultado de la celda se asigna a la clase especial “sin clasificar”.

En consecuencia, la superficie clasificada viene determinada, principalmente, por la fidelidad exigida (cuanto menor es la fidelidad, mayor es la incertidumbre en las asignaciones pero mayor superficie podemos clasificar). Del informe resultado del proceso de clasificación híbrida se pueden derivar otros indicadores que son potencialmente interesantes para la estimación del error en la asignación: promiscuidad (P) [logaritmo en base 10 del número de categorías temáticas a las que puede corresponder cada clase estadística], clases

mayoritarias (Q) [número de categorías temáticas con fidelidad mayor al 15% para cada clase estadística, que puede tomar un valor entero entre 0 y 6], y fidelidad y representatividad para las segundas y terceras categorías temáticas para cada clase estadística (F2, F3, R2 y R3).

Además de los criterios propios de cada clasificador, puede pensarse en otros estimadores de la incertidumbre en el mapa resultante. Entre ellos destacamos la entropía (H), que se ha empleado en estudios similares (Foody, 1995, 2009) en base a lo expuesto en Klir y Folger (1988) y es máxima cuando la probabilidad de pertenencia a una clase se distribuye homogéneamente entre todas las categorías, y la incertidumbre (I) definida en Eastman (2001) y adaptada a nuestro caso de la siguiente forma (Ecuación 1):

$$I = 1 - \frac{F - \frac{F + F2 + F3}{3}}{1 - \frac{1}{3}} \quad (1)$$

En esta fórmula, F corresponde al valor de fidelidad (clasificador híbrido) para las tres categorías temáticas con los valores de F más altos.

3.4. Modelización de la distribución espacial de la exactitud

En este estudio, se han realizado dos aproximaciones, una basada en píxeles, donde la variable dependiente es el acierto/error (obtenida de la comparación entre la clasificación híbrida y el 25% de píxeles del mapa de cubiertas) y que ha sido tratada a través de regresión logística (Balakrishnan, 1992) y otra basada en polígonos, donde la variable dependiente es el porcentaje de aciertos en los

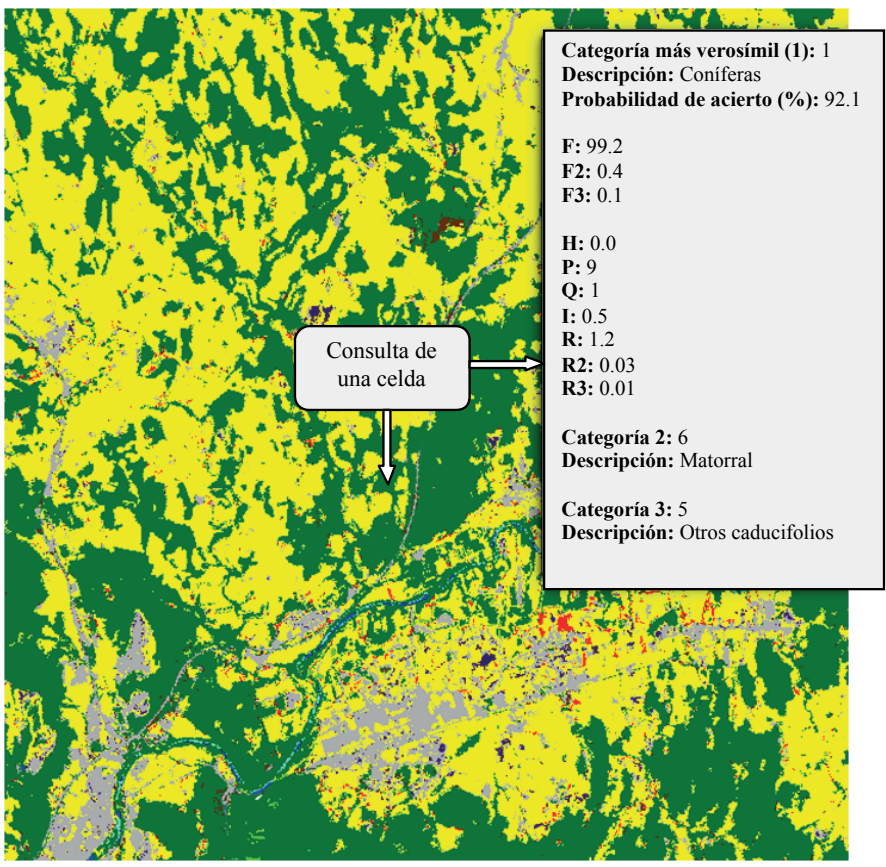


Figura 2. Fragmento del ráster multibanda resultante de la clasificación y aspecto de una consulta sobre una celda (píxel), que muestra no sólo la categoría más verosímil, sino también las dos siguientes, así como los parámetros que permiten estimar la probabilidad de acierto de dicha celda.

polígonos de cada clase estadística, convenientemente normalizado, y que ha sido tratada a través de regresión múltiple; las variables en porcentaje se han transformado aplicando la función del arco-seno a la raíz cuadrada de sus valores en tanto por uno para adecuar la distribución de sus valores en la modelización. En el caso de la regresión logística, y por limitaciones de SPSS (v. 18) en nuestros ordenadores, los resultados han sido obtenidos en una muestra aleatoria del 5% de los datos (que representa unos 3,5 millones de píxeles).

En la regresión múltiple, la transición del análisis al nivel de objeto se consigue mediante el enriquecimiento de los polígonos de test (Serra *et al.*, 2009); para el enriquecimiento de estos polígonos se combina la capa de la verdad terreno de test del MCSC con las diferentes variables independientes y se generan estadísticos en cada polígono para cada variable. Estos estadísticos, en concreto los de centralidad como la media o, en nuestro caso, la mediana, se correlacionan con un modelo de regresión lineal ponderado por la superficie del polígono con el porcentaje de acierto de aquel polígono (porcentaje de píxeles correctos que contiene).

4. Resultados y conclusiones

El producto final es una imagen multibanda que une el producto de la clasificación con el mapa de espacialización de la exactitud resultado de la aplicación del modelo así como con las capas (bandas) indicadoras de la calidad del proceso (F,

F2, F3, R, etc.). La Figura 2 muestra un ejemplo de resultado de una consulta sobre una celda (píxel) del mapa obtenido. La exactitud global fue derivada de una matriz de confusión, obteniéndose un 85,4% de acierto y una área clasificada del 85,1% en el caso de un valor umbral de fidelidad del 50% (Tabla 1). Como puede apreciarse en la tabla, los errores de comisión para la mayoría de las clases son razonablemente bajos y bien repartidos entre ellas, excepto para los castaños, que presentan una comprensible confusión con hayedos y, en menor medida, con otros caducifolios dada su respuesta espectral, fenología y distribución geográfica similares; en cuanto a los errores de omisión, los más notables aparecen para las categorías de matorrales y de pastos, los primeros principalmente confundidos con coníferas, de las cuales son un estadio intermedio en la sucesión ecológica y los segundos con cultivos herbáceos, dada su similitud espectral; podría intentarse mejorar el resultado en alguna de estas categorías más problemáticas, pero también es cierto que para nuestros propósitos resulta positivo tener diversidad de calidades en el área cartografiada para poder comprobar la bondad del método propuesto incluso para reflejar estas zonas. Para el caso de una fidelidad equivalente a 0% (Tabla 2), el acierto baja al 81,9%, pero el área clasificada asciende al 100%, siendo el escenario resultante de este trabajo ya que se deseaba que la clasificación final incluyera toda el área de estudio. En efecto, un umbral de fidelidad nulo permite clasificar el máximo número de píxeles posible (aunque algunos estén erróneamente

Tabla 1. Matriz de confusión al clasificar con una fidelidad del 50%.

	1	2	3	4	5	6	7	8	9	10	11	12	Total	EC	EU
0	43709	25874	4614	2656	17949	46181	14376	200	8349	49790	49102	0	262800		
1	601595	48581	138	786	11241	43294	370	2	1	997	4998	0	712003	15.5	84.5
2	51440	440677	2689	353	5958	14077	49	0	0	242	186	0	515671	14.5	85.5
3	97	783	16488	7123	2643	42	23	0	0	4	0	0	27203	39.4	60.6
4	616	1005	5025	52337	11477	62	631	0	0	36	5	0	71194	26.5	73.5
5	6163	9327	1401	11144	83534	1498	1004	5	7	3107	157	0	117347	28.8	71.2
6	16560	8059	0	1	237	109408	2225	17	70	2828	6575	0	145980	25.1	74.9
7	645	30	1	193	706	995	35709	0	0	3919	1875	0	44073	19.0	81
8	0	0	0	0	1	1	0	3962	0	112	9	0	4085	3.0	97
9	13	2	0	0	23	275	601	0	80401	6184	7697	0	95196	15.5	84.5
10	3008	1046	7	5	6413	9009	16761	569	5702	680948	29520	0	752988	9.6	90.4
11	2912	175	0	0	323	8188	5494	5	8591	22590	377298	16	425592	11.3	88.7
12	0	0	0	0	1	1	0	0	0	0	34	1469	1505	2.4	97.6
Total	726758	535559	30363	74598	140506	233031	77243	4760	103121	770757	477456	1485	3175637		
EO	17.2	17.7	45.7	29.8	40.5	53.1	53.8	16.8	22	11.7	21	1.1			
EP	82.8	82.3	54.3	70.2	59.5	46.9	46.2	83.2	78	88.3	79	98.9			
Total s/c	683049	509685	25749	71942	122557	186850	62867	4560	94772	720967	428354	1485			
EO s/c	11.9	13.5	36.0	27.3	31.8	41.4	43.2	13.1	15.2	5.6	11.9	1.1			
EP s/c	88.1	86.5	64.0	72.7	68.2	58.6	56.8	86.9	84.8	94.4	88.1	98.9			

1. Coníferas; 2. Esclerófilas; 3. Castaños; 4. Hayedos; 5. Otros caducifolios; 6. Matorrales; 7. Pastos; 8. Arrozales; 9. Viñedos; 10. Frutales y otros herbáceos; 11. Suelo urbano y desnudo; 12. Agua. EC: Error de comisión; EU: Exactitud del usuario; EO: Error de omisión; EP: Exactitud del productor; s/c: Sobre el total de píxeles clasificados (código no 0).

Tabla 2. Matriz de confusión al clasificar con una fidelidad del 0%.

	1	2	3	4	5	6	7	8	9	10	11	12	Total	EC	EU
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	625413	56183	164	826	13919	54345	744	3	9	3560	9427	0	764593	18.2	81.8
2	55634	448829	3262	829	8602	16468	211	7	1	914	450	0	535207	16.1	83.9
3	123	1130	18049	7458	3914	61	23	0	0	5	0	0	30763	41.3	58.7
4	616	1005	5025	52337	11477	62	631	0	0	36	5	0	71194	26.5	73.5
5	6809	9936	2472	12223	87228	1857	1543	5	7	4294	207	0	126581	31.1	68.9
6	24611	13538	5	31	1689	126513	3438	25	133	5734	10730	0	186447	32.1	67.9
7	1203	186	1308	812	2195	1529	39400	0	0	4547	2490	0	53670	26.6	73.4
8	0	0	0	0	1	1	0	3962	0	112	9	0	4085	3	97
9	13	2	0	0	23	275	601	0	80401	6482	7697	0	95494	15.8	84.2
10	5809	3793	78	70	10534	18052	23239	671	11592	764986	49326	0	888150	13.9	86.1
11	6527	957	0	12	923	13867	7413	87	10978	33234	397081	16	471095	15.7	84.3
12	0	0	0	0	1	1	0	0	0	0	34	1469	1505	2.4	97.6
Total	726758	535559	30363	74598	140506	233031	77243	4760	103121	823904	477456	1485	3228784	20.2	15.6
EO	13.9	16.2	40.6	29.8	37.9	45.7	49	16.8	22	7.2	16.8	1.1	24.8	18.0	19.4
EP	86.1	83.8	59.4	70.2	62.1	54.3	51	83.2	78	92.8	83.2	98.9			

1. Coníferas; 2. Esclerófilas; 3. Castaños; 4. Hayedos; 5. Otros caducifolios; 6. Matorrales; 7. Pastos; 8. Arrozales; 9. Viñedos; 10. Frutales y otros herbáceos; 11. Suelo urbano y desnudo; 12. Agua. EC: Error de comisión; EU: Exactitud del usuario; EO: Error de omisión; EP: Exactitud del productor; s/c: Sobre el total de píxeles clasificados (código no 0).

clasificados), lo que es útil a nuestros propósitos de entender cómo podemos modelizar la distribución espacial del error en un ámbito lo más general de situaciones, más que sacrificar la cartografía de zonas donde muy presumiblemente el resultado puede ser erróneo.

Pasando ya a la modelización de la distribución espacial de la exactitud, en el caso de la aproximación por píxel, los resultados de la regresión logística (con la opción *forward stepwise* y un valor

de corte del 50% de probabilidad de acierto) mostraron que la variable más explicativa del acierto es la primera fidelidad (la máxima), mientras que la segunda variable más explicativa corresponde a la entropía, en este caso con una relación inversa, como resulta lógico. El área bajo la curva ROC (AUC) muestra un resultado final explicativo de 0,75. Con los resultados de la regresión logística aplicados a toda el área de estudio, se extrajeron los píxeles con probabilidades de acierto superiores e inferiores al 50% y se compararon con las




Figura 3. Ejemplo de aciertos y errores predichos. El fragmento corresponde a la categoría “agua” localizada en un embalse.

categorías del MCSC, obteniéndose la espacialización de los aciertos y errores predichos. La Figura 3 muestra un ejemplo de los resultados en el caso del agua, correspondiente a un embalse, categoría que ha sido individualizada en la figura para facilitar la comprensión. Como se observa, en el centro del embalse el acierto predicho es claramente mayoritario, abarcando la masa de agua más profunda y continua, mientras que el error predicho se localiza en los márgenes del embalse. Este resultado es comprensible debido a la mayor heterogeneidad de las zonas marginales y a la diferencia en el nivel del agua del embalse entre las diferentes fechas de las imágenes de satélite y la del MCSC.

En el caso de la aproximación por objeto, un test totalmente independiente basado en aproximadamente un 25% de la superficie útil de la imagen ha revelado una fiabilidad de la estimación de la exactitud en el mapa muy elevada, de un 93,1%, altamente coherente con la que se obtuvo con el propio modelo (94,3%), construido con un 25% de la superficie (el restante 50% había sido usado para entrenar el clasificador).

Agradecimientos

Este trabajo se ha realizado en el marco del proyecto financiado por la Comisión Europea “*QUALity aware VIvisualisation for the Global Earth Observation system of systems (GeoViQua)*”, ref. FP7 ENV.2010.4.1.2-2 265178, y del proyecto financiado por el Ministerio de Economía y Competitividad del Gobierno de España “Análisis espaciotemporal de las cubiertas del suelo y del estrés de la vegetación en la P. Ibérica a la luz de medio Siglo (1975-2025) de dinámica climática y sus anomalías (DinaCliVe)”, ref. CGL2012-33927. Xavier Pons es beneficiario de un *ICREA Academia Excellence in Research grant* (2011-2015).

Referencias

Balakrishnan, N. 1992. Handbook of the logistic distribution. New York: Marcel Dekker.

Burriel, J.A., Ibáñez, J.J., Pons, X. 2005. Segunda edición del mapa de cubiertas del suelo de Cataluña: Herramienta para la gestión sostenible del territorio. *Cuadernos de la Sociedad Española de Ciencias Forestales*, 19: 35-39.

CREAF. 2007. *Mapa de cobertes del sòl de Catalunya*. http://www.creaf.uab.cat/cat/projectes/10_229.htm

Eastman, J. R. 2001. IDRISI32 Release2: Guide to GIS and Image Processing. Worcester: Clark University.

Foody, G.M. 1995. Cross-entropy for the evaluation of the accuracy of a fuzzy land cover classification with fuzzy ground data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 50(5): 2-12. [http://dx.doi.org/10.1016/0924-2716\(95\)90116-V](http://dx.doi.org/10.1016/0924-2716(95)90116-V)

Foody, G.M. 2009. Sample size determination for image classification accuracy assessment and comparison. *International Journal of Remote Sensing*, 30(20): 5273-5291. <http://dx.doi.org/10.1080/01431160903130937>

Klir, G.J., Folger, T.A. 1988. Fuzzy sets, uncertainty and information. London: Prentice-Hall International.

Moré, G., Pons, X., Serra, P. 2006. Improvements on Classification by Tolerating NoData Values - Application to a Hybrid Classifier to Discriminate Mediterranean Vegetation with a Detailed Legend Using Multitemporal Series of Images. En: *Geoscience and Remote Sensing Symposium, 2006. IGARSS 2006. IEEE*. pp. 192-195. <http://dx.doi.org/10.1109/IGARSS.2006.54>

Ninyerola, M., Pons, X., Roure, J.M. 2000. A methodological approach of climatological modelling of air temperature and precipitation through GIS techniques. *International Journal of Climatology*, 20: 1823-1841. [http://dx.doi.org/10.1002/1097-0088\(20001130\)20:14%3C1823::AID-JOC566%3E3.0.CO;2-B](http://dx.doi.org/10.1002/1097-0088(20001130)20:14%3C1823::AID-JOC566%3E3.0.CO;2-B)

Norušis, M.J. 2002. SPSS 11,0: Guide to data analysis. Upper Saddle River: Prentice Hall.

Palà, V., Pons, X. 1995. Incorporation of relief in polynomial based geometric corrections. *Photogrammetric Engineering & Remote Sensing*, 61(9): 935-944.

Pons, X., Solé-Sugrañes, L. 1994. A simple radiometric correction model to improve automatic mapping of vegetation from multispectral satellite data. *Remote Sensing of Environment*, 48(2): 191-204. [http://dx.doi.org/10.1016/0034-4257\(94\)90141-4](http://dx.doi.org/10.1016/0034-4257(94)90141-4)

Pons, X. 2004. *MiraMon. Geographic Information System and Remote Sensing software*. Bellaterra: CREAM.

Pons, X., Ninyerola, M. 2008. Mapping a topographic global solar radiation model implemented in a GIS and refined with ground data. *International Journal of Climatology*, 28: 182-1834. <http://dx.doi.org/10.1002/joc.1676>

Pons, X., Moré, G., Pesquer, L. 2010. Automatic matching of Landsat image series to high resolution orthorectified imagery. En: *Proceedings of the ESA Living Planet Symposium*, CD-ROM edition, ESA reference document: SP-686.

- Pons, X., Pesquer, L., Cristóbal, J., González-Guerrero, O. 2014. Automatic and improved radiometric correction of Landsat imagery using reference values from MODIS surface reflectance images. *International Journal of Applied Earth Observation and Geoinformation*, 33: 243-254. <http://dx.doi.org/10.1016/j.jag.2014.06.002>
- Pons, X., Arcalís, A. 2012. Diccionari terminològic de teledetecció. Barcelona: Enciclopèdia Catalana e Institut Cartogràfic de Catalunya.
- Rouse, J.W.J., Haas, R.H., Schell, J.A., Deering, D.W. 1973. Monitoring vegetation systems in the Great Plains with ERTS. En *Third Earth Resources Technology Satellite-1 Symposium*, NASA, Washington DC, EE.UU, pp 309-317.
- Serra, P., Moré, G., Pons, X. 2009. Thematic accuracy consequences in cadastre land-cover enrichment from a pixel and from a polygon perspective. *Photogrammetric Engineering and Remote Sensing*, 75(12): 1441-1449. <http://dx.doi.org/10.14358/PERS.75.12.1441>
- Serra, P., Pons, X. 2008. Monitoring farmers' decisions on Mediterranean irrigated crops using satellite image time series. *International Journal of Remote Sensing*, 29(8): 2293-2316. <http://dx.doi.org/10.1080/01431160701408444>