# Cartografiado de la Vid con datos Landsat-TM. Aplicación a una Zona de Tomelloso (Ciudad Real)

E. Rubio\*, M. M. Artigao\*\*, V. Caselles\*, C. Coll\*, y E. Valor\* Correo electrónico: Eva.M.Rubio@uv.es

\* Dept. de Termodinámica. Univ. de Valencia. c/ Dr. Moliner 50. 46100 Burjassot. Valencia

\*\* Dept. de Física Aplicada. Univ. de Castilla-La Mancha. Avda España s/n. Albacete

#### RESUMEN

La escasa cobertura vegetal que presenta el viñedo lo convierten en un cultivo difícil de cartografiar a partir de imágenes de satélite, siendo fácilmente confundible con el olivo o zonas en barbecho. Por ello, con frecuencia se utilizan técnicas multiestacionales basadas en la distinta evolución fenológica de los cultivos de la zona. En este trabajo proponemos una técnica para mejorar la precisión en la clasificación del viñedo, a partir de una única imagen Landsat- Thematic Mapper, seleccionando aquellas combinaciones de bandas que optimizan la separabilidad espectral de uno o más usos de suelo. La clasificación definitiva es resultado de las clasificaciones parciales, con una precisión final del 91% para el cultivo de viñedo de una zona de Tomelloso (Ciudad Real).

PALABRAS CLAVE: teledetección, clasificación, Landsat-TM, viñedo.

# ABSTRACT

In general, mapping vineyards is difficult because of the small height and green cover of the vines, being easily mistaken for olive trees or fallow. Then, it could be convenient to perform a multitemporal classification based on the different stages of the crop development. This work is concerned with a strategy to improve the accuracy of the vine mapping, with one Landsat-Thematic Mapped image alone, selecting the most appropriate channel combinations to discriminate one or several land cover uses. The definitive land mapping will be generated from the preliminary maps, giving a final accuracy of 91% for the vineyard in a zone of Tomelloso (Ciudad Real).

KEY WORDS: remote sensing, land cover mapping, Landsat-TM, vineyard

# INTRODUCCIÓN

Una de las principales dificultades que presenta el cartografiado de un cultivo como el viñedo es su escasa cobertura frente a la del suelo. Por un lado, variaciones en la humedad, composición y brillo del suelo pueden forzar una definición excesivamente ambigua de la clase Vid; y por otro, la presencia en la misma zona de matorrales, cultivos tipo olivo o zonas en barbecho puede ser fuente de confusión. De aquí que sea conveniente acudir a métodos multi-estacionales que basan la clasificación en la distinta evolución fenológica de estos cultivos (Lanjeri, 1996).

En este trabajo presentamos un método que permite cartografiar el viñedo con una buena precisión usando una única imagen Landsat-TM de la zona. Esto se consigue tratando de incrementar la separabilidad de la categoría Vid con respecto al resto de clases. Esta metodología ha sido aplicada para cartografiar las parcelas de viñedo en una zona del término de Tomelloso, provincia de Ciudad Real, en junio de 1994. Entre los años 1991 y 1997 parte del viñedo fue reemplazado por otros cultivos de tipo herbáceo, no existiendo un inventario válido del viñedo para ese año. De aquí la importancia de este tipo de estudios. En la sección que sigue se describe la zona de estudio. La segunda sección se centra en el proceso de identificación de las combinaciones de bandas TM a usar en la clasificación de la Vid. En este punto se utilizará la información aportada por una primera clasificación no supervisada y la información verdad-terreno de que disponíamos. Las dos secciones que siguen corresponden al proceso de clasificación propiamente dicho y de validación del mapa resultante usando distintos estimadores de la precisión. La última sección contiene las principales conclusiones de este trabajo.

# **ZONA DE ESTUDIO**

La zona de Tomelloso cartografiada es una extensión bastante uniforme situada a unos 670 m sobre el nivel del mar, que no presenta grandes desniveles pero que se halla recorrida por barrancos de hasta un 8% de pendiente, que atraviesan la zona de Norte a Sur conectando dos acuíferos. Los suelos de esta zona son bastante pobres, tratándose de inceptisoles en su mayoría. Destacan por su escasa profundidad, con una franja caliza situada a unos 50 cm de la superficie (Bolle y Streckenbach, 1993). El viñedo de la variedad Airen es el cultivo mayoritario, coexiste con cereal de secano y en menor proporción con olivo, leguminosas, matorral y monte bajo, pudiendo llegar a ser considerable la extensión de las parcelas en barbecho.

Para el cartografiado del viñedo contamos con una imagen Thematic Mapper (Landsat-5) del 4 de junio de 1994. Esta zona fue zona piloto del proyecto EFEDA, motivo por el cual hemos dispuesto de información verdad-terreno sobre los cultivos entonces presentes en una treintena de parcelas (F. Montero, 1997, comunicación personal). Esta información ha sido contrastada con un mapa de usos de suelo para el año 1991 (Barth y Runge, 1992) y con visitas de reconocimiento de la zona en verano de 1997.

La distribución típica de las cepas Airen en Tomelloso es ocupando los vértices de cuadros de unos 2,5 m de lado. En el mes de junio la cepa todavía no alcanza el metro de altura ni de diámetro lo cual se traduce en una proporción cepa frente a suelo desnudo inferior al 15 %. De aquí que sea un cultivo fácilmente confundible con otras especies tipo olivo o con terrenos en barbecho. Por contra, el avanzado estado fenológico del cereal en comparación con la poco desarrollada cepa facilitará la labor de clasificación.

#### SELECCIÓN DE BANDAS TM

Consideramos que una combinación de bandas TM es más adecuada para efectuar la clasificación de la Vid que otra, si conduce a una mayor separabilidad espectral de la Vid frente al resto de clases. Por consiguiente, previamente es necesario establecer qué clases temáticas de interés (leyenda del mapa final) intervendrán en una clasificación supervisada. Con el fin de asegurar una total reciprocidad entre estas clases temáticas y las posibles clases espectrales presentes en la imagen, definiremos estas últimas a partir de las clases espectrales obtenidas en una clasificación no supervisada. Ahora bien, al proceder de este modo podemos entrar en conflicto, dado que la definición de estas clases está a su vez supeditada a las bandas espectrales usadas en la clasificación no supervisada.

Los pasos que hemos seguido son: en primer lugar efectuar una clasificación no supervisada usando las bandas 1-5 y 7 del TM. A continuación, identificar cada una de estas clases espectrales como usos de suelo, agua o nubes. Y por último, caracterizar espectralmente cada clase temática.

Sobre la clasificación no supervisada identificamos una docena de zonas espectralmente homogéneas que por su forma y ubicación corresponden a parcelas de las cuales disponemos de información verdad-terreno. De este modo establecemos una correspondencia entre clases espectrales presentes y usos del suelo. Al efectuar esta identificación comprobamos que, en algunos casos, un mismo uso de suelo responde a más de una clase espectral, como resultado de variaciones del substrato entre otros. En consecuencia, definimos más de una "subclase" espectral para cada clase temática. En la Tabla 1 se muestran las ocho categorías espectrales resultantes y la leyenda más general a la que se verán reducidas las anteriores al final de este proceso. De esta forma, se resuelve el conflicto de la definición de las clases espectrales ya que hemos identificado parcelas que sabemos a qué tipo de superficie corresponden, y son estas parcelas las que usaremos ahora en la selección de las bandas, y después en la fase de entrenamiento.

El siguiente paso es la caracterización espectral de cada clase, para ello efectuamos un muestreo y sobre estas muestras calculamos sus estadísticas. En nuestro caso, preferimos usar un muestreo en conglomerados ("clusters") por ser una técnica más eficiente en términos de coste para la toma de muestras, pese al fenómeno de la auto-correlación espacial (Moisen et al., 1994). Así, trazamos muestras de pequeño tamaño (siempre inferior a 25 píxel) con el fin de no infravalorar la variabilidad de cada categoría. En cuanto al número de muestras a tomar depende de factores como son: (1) la heterogeneidad inherente a cada categoría; (2) la importancia relativa de la categoría dentro de los objetivos de la clasificación; y (3) el esquema de muestreo que se haya utilizado. En este caso, tomamos un número de muestras de entrenamiento suficiente para evaluar su precisión de forma adecuada

Así para la clase Bar1 tomamos 468 píxel, 106 para la clase Bar2, 166 para Cer1, 245 para Cer2, 171 para Cer3, 470 para Oli1, 576 para Vid1, y 362 para la clase Vid2. Con estos datos producimos la signatura espectral de cada categoría para todas las bandas TM (Figura 1).



Figura 1. Diagrama de signaturas espectrales para las clases que intervienen en la clasificación.

A continuación, utilizamos estas muestras caracterizadas espectralmente para calcular la separabilidad espectral entre clases. Una baja separabilidad espectral es normalmente producida por una selección no adecuada de las bandas y/ o de las muestras de entrenamiento. Como hemos dicho, la selección de las clases y las muestras de entrenamiento se basó en los resultados de una clasificación no supervisada. Por ello, en este punto del trabajo, descartamos las opciones de definir nuevas clases o modificar las zonas de entrenamiento buscando que aquéllas sean más separables, y nos centramos en identificar la combinación o combinaciones que son más apropiadas para separar las clases de la Tabla 1.



Tabla 1. Relación entre clases espectrales y clases temáticas

El criterio que seguimos para seleccionar estas combinaciones de bandas es escoger aquellas combinaciones para las cuales la categoría genérica Vid presenta la máxima separabilidad con respecto a las demás. Para ello usamos la distancia de Bhattachary ya entre dos clases (i, j), DB(i, j), cuya expresión general es de la forma (Richards, 1986):

$$DB(i,j)=2\cdot[1-exp(-a(i,j))]$$
(1)

con

$$a(i,j)=0,125[M(i)-M(j)]^{T} \cdot [0,5(S(i)+S(j)]^{-1} \cdot [M(i)-M(j)]$$

$$0.5 \operatorname{Ln}\left\{\frac{\left|0.5(\mathrm{S}(\mathrm{i})+\mathrm{S}(\mathrm{j})\right|}{\sqrt{\left|(\mathrm{S}(\mathrm{i})^{*}\mathrm{S}(\mathrm{j})\right|}\right|}\right\}$$

donde M(i) es el n-vector medio de la clase i; y S(i) es la (nxn)-matriz de covarianza para la clase i, siendo n el número de canales. Esta distancia puede tomar valores entre 0 y 2, donde un 0 indicaría que las dos clases están completamente solapadas y un 2 indicaría una separación completa.

Calculamos esta distancia, DB, para todos los posibles pares de clases y todas las combinaciones bicanales de las 6 bandas TM, esto es, haciendo n =2 en la ecuación (1). Para cada una de estas combinaciones bicanales, evaluamos el valor medio de las distancias entre la clase Vid (Vid1(Vid2) y el resto de clases (Tabla 2). Queremos señalar que los valores de esta tabla corresponden a distancias medias para cada par de bandas TM, por lo que no se pueden comparar con los valores que se tendría para cada par de clases y varias bandas.

A la vista de estos resultados, la combinación 3-4 se revela como la más apropiada. Si además analizamos estas mismas distancias a nivel de categorías en lugar de como distancias medias re-



Tabla 2. Valores promedio de la distancia de Bhattachary ya entre la media de las clases espectrales Vid1 y Vid2 y el resto de clases para las posibles combinaciones bicanales del TM.

resulta que los valores más elevados de separabilidad para las categorías Bar1, Bar2, Cer2, y Vid1 se dan para las combinaciones 1-3, 1-4 y 3-4; mientras que para las categorías Cer1, Cer3 y Vid2 son las combinaciones 3-4, 3-5 y 4-5 las que dan valores más elevados. Por consiguiente, concluimos que la combinación 1-3-4, por un lado, y la combinación 3-4-5, por otro, son una buena elección para la clasificación. También a partir de estas distancias comprobamos que para combinaciones bicanales como 1-3, 1-4, 1-2, entre otras, el Olivo es la clase que más se confunde con la Vid. Por este motivo, esta clase sólo intervendrá al utilizar la combinación de canales TM 3-4-5 y no con la combinación 1-3-4. Con esta eliminación se consigue aumentar la separabilidad media de la Vid con respecto a las demás clases en un 11%.

#### CLASIFICACIÓN

Finalizada la fase de entrenamiento y el estudio de las categorías que intervienen en la clasificación, iniciamos la fase de asignación. Con cada una de las dos combinaciones de canales elegidas efectuamos sendas clasificaciones supervisadas usando un clasificador de máxima probabilidad "fuzzy". En adelante nos referiremos a la clasificación obtenida con la combinación de bandas TM 1, 3 y 4 como "aproximación 1-3-4"; y a la clasificación resultado de usar las bandas TM 3, 4 y 5 como "aproximación 3- 4-5". El algoritmo de máxima probabilidad asigna a cada píxel distintos grados (entre 0 y 1) o probabilidades de pertenencia a cada una de las clases. Para calcular este grado de pertenencia se utiliza un umbral gausiano, almacenado en la signatura de cada clase, que permite determinar si un píxel dado pertenece a esta clase o no. El umbral es el radio (en unidades de desviación estándar) de un hiperelipsoide que envuelve la signatura media de la clase en el espacio de signaturas. Si el píxel queda dentro del hiperelipsoide entonces se le asigna una probabilidad de pertenencia a la clase. Al aplicar este algoritmo es posible definir una desviación o probabilidad a priori de pertenencia a la clase i y de este modo forzar la clasificación para que la proporción de píxels de la clase i sea la indicada. En nuestro caso, atribuimos a todas las clases la misma probabilidad.

En ambas aproximaciones consideramos las clases listadas en la Tabla 1, con excepción de la clase Oli1 en la aproximación 1-3-4 por ser la clase que más se confunde con la Vid. También en ambas aproximaciones intervienen tres clases más correspondientes a nubes (no mencionadas en la discusión anterior por no presentar problemas). En cuanto al muestreo utilizamos los mismos datos que en la selección de las bandas. La clasificación definitiva resulta de las dos anteriores tomando de cada una de ellas los resultados que presentan una mayor fiabilidad. La cuestión que queda por resolver es precisamente cuál es la precisión de estas dos aproximaciones y cuáles son las categorías que en cada una de ellas presentan una mayor fiabilidad. Veamos primero cómo se evalúan estas precisiones.

## MEDIDAS DE PRECISIÓN EN UNA CLASIFICACIÓN

Una de las formas más ampliamente aceptadas de estimar la precisión de una clasificación es a través de la matriz de error o confusión. Para ello es condición indispensable que esta matriz sea representativa del área completa clasificada (Congalton, 1988a). La matriz de error se construye a partir de un muestreo en el que se identifican datos verdad terreno o de referencia sobre la clasificación generada. En ella se especifica el número total de muestras de referencia (píxel) que siendo de un tipo dado que han sido asignadas a cada una de las clases. En concreto, las columnas representan los datos de referencia mientras que las filas representan la clasificación generada. A partir de esta matriz de confusión se define toda una serie de estimadores de la precisión los cuales condensan en mayor o menor proporción parte de la información contenida en aquélla. La preferencia por uno u otro de estos estimadores debe ser función del objetivo que se tenga.

La fiabilidad global,  $P_c$ , es un estimador de la precisión del mapa completo. Viene dada por el número de muestras correctamente clasificadas frente al número total de muestras. Para una matriz de error normalizada al número total de muestras se cumple que:

$$P_{c} = \sum_{i=1}^{m} x_{ii}$$
 (2)

siendo X<sub>ii</sub> el acuerdo observado, que viene dado por los elementos de la diagonal principal de la matriz, y m el número de clases. A nivel de categorías, se definen dos estimadores (Story y Congalton, 1986): (1) La fiabilidad del productor para la clase i, F<sub>pi</sub>, indica la probabilidad condicional de que un píxel de la clase i esté correctamente clasificado, y se calcula como:

$$F_{pi} = \frac{X_{ii}}{X_{+i}}$$
(3)

(2) La fiabilidad del usuario, F<sub>ui</sub>, indica la probabilidad condicional de que un píxel clasificado en la imagen como clase i corresponda realmente a dicha clase sobre el terreno. Ésta se calcula como

$$F_{ui} = \frac{x_{ii}}{x_{i+}}$$
(4)

donde  $X_{+i}$  y  $X_{i+}$  son respectivamente, los marginales de la columna y de la fila i de la matriz. Otro estimador de la precisión en una clasificación es el coeficiente kappa (Bishop et al., 1975), el cual calcula el acuerdo imagen clasificada-realidad observada debido únicamente a la exactitud de la clasificación, suprimiendo el acuerdo que cabría esperar simplemente por azar. Además del coeficiente kappa global,  $\kappa$ , se definen el coeficiente kappa condicional de los datos de referencia i,  $\kappa_{pi}$ , y el coeficiente kappa condicional de los datos del mapa clasificados como clase i,  $\kappa_{ui}$ , (Stehman, 1997a). Una expresión general del coeficiente k global es la siguiente:

$$\kappa = \frac{P_c - P_a}{1 - P_a} \tag{5}$$

donde  $P_c$  es como hemos dicho el acuerdo observado y  $P_a$  es una estimación del acuerdo por azar. El coeficiente kappa condicional para los datos de referencia en la categoría i es de la forma:

$$\kappa_{\rm pi} = \frac{F_{\rm pi} - X_{\rm i+}}{1 - X_{\rm i+}} \tag{6}$$

Y el coeficiente kappa condicional para los datos del mapa clasificados en la categoría i es de la forma:

$$\kappa_{ui} = \frac{F_{ui} - X_{+i}}{1 - X_{+i}}$$
(7)

La expresión de  $P_a$  depende de si en la clasificación se ha fijado o no la probabilidad *a priori* de que un píxel sea asignado a la clase i (Stehman, 1997a). En nuestro caso, un píxel tiene la misma probabilidad de ser clasificado como cualquiera de las m clases i, por lo tanto  $P_a = 1/m$ . Haciendo este cambio se obtiene la expresión del coeficiente kappa que proponen Brennan y Prediger (1981). Si se sustituye esta expresión de  $P_a$  en la ecuación (6) entonces se puede comprobar que k es una función lineal de  $P_c$ , y por lo tanto no aporta información adicional.

Una expresión alternativa y bastante extendida de  $P_a$  es:

$$P_a = \sum_i X_{i+} X_{+i}$$
(8)

que aunque más difícil de interpretar (Stehman, 1997a), sí incorpora información sobre la matriz de error de fuera de la diagonal principal (Dicks y Lo, 1990; Janssen y van der Wel, 1994).

#### SELECCIÓN DE CLASES

En este punto determinaremos la precisión del proceso entero de clasificación, lo cual implica evaluar no sólo el resultado de la clasificación sino también el esquema de muestreo y la fase de entrenamiento. Al final de este punto estableceremos un protocolo para generar la clasificación definitiva a partir de las dos aproximaciones 1-3-4 y 3-4-5. Para ello identificaremos las clases que en cada aproximación presentan la mayor precisión.

El orden que vamos a seguir es: En primer lugar, estudiar la bondad de las clases y muestras de entrenamiento (usados hasta el momento) en términos de su definición espectral. En segundo lugar, presentar una medida absoluta de la precisión de cada una de las dos aproximaciones a nivel global y de categorías individuales (con datos independientes: muestras de referencia). Y por último concluir qué clases tomar de cada aproximación.

#### Bondad de las clases y datos de entrenamiento

La definición espectral idónea de una clase es aquélla que abarcando toda la variabilidad inherente a la clase en cuestión no llega a ser tan amplia como para originar confusión entre clases. Relacionado con estas características se encuentran los errores de omisión, E<sub>0</sub>, y de comisión, E<sub>0</sub>, de la clase i, los cuales tienen su origen en una definición imperfecta de la categoría o en una delimitación excesivamente amplia de la misma (Chuvieco 1990). Estos se definen a partir de la matriz de error de la siguiente manera:

$$E_{oi} = \frac{X_{i+} - X_{ii}}{X_{\cdot}} \tag{9}$$

$$E_{ei} = \frac{X_{+i} - X_{ii}}{X_{+i}}$$
(10)

donde X<sub>ii</sub> es el elemento i de la diagonal principal de la matriz, y X<sub>i+</sub> y X<sub>+i</sub> son los marginales de la fila y de la columna i, respectivamente. Como se trata de estudiar la fase de entrenamiento construimos la matriz de error de tal modo que las columnas contengan los datos de entrenamiento, en lugar de los de referencia, y las filas contengan la clasificación generada. Tal y como acabamos de indicar, para cada una de las dos aproximaciones calculamos sendas matrices de error y los subsiguientes errores de omisión y comisión de cada clase (Tabla 3).

	Aproxima	ción 1-3-4	Aproximación 3-4-5		
	Eoi	Eci	Eoi	Eci	
Bar1	0	0,09	0,2	0,2	
Bar2	0,17	0	0,4	0,3	
Cer1	0,6	0,6	0	0	
Cer2	0,08	0,09	0,3	0,3	
Cer3	0,14	0,3	0,07	0,3	
Oli1	-	-	0,5	0,2	
Vid1	0,13	0,3	0,3	0,4	
Vid2	0,3	0,2	0,18	0,2	

**Tabla 3.** Errores de omisión, Eoi, y de comisión, Eci, para cada una de las clases usadas en las aproximaciones 1-3-4 (columnas segunda y tercera) y 3-4-5 (columnas cuarta y quinta).

Los resultados de esta tabla muestran que efectivamente existen algunas clases que están mejor d e finidas en una aproximación que en la otra y viceversa. En concreto, las clases Bar1, Bar2, Cer2 y Vid1 presentan menores errores de omisión y comisión en la aproximación 1-3-4; mientras que estos errores son menores para el resto de las clases en la aproximación 3-4-5. Estos resultados son coherentes con los obtenidos a partir de la distancia de Bhattachary ya. Los errores de omisión y de comisión de las clases Vid1 y Vi d 2, son debidos en gran parte a errores de clasificación entre ellas, como se puede comprobar claramente en las matrices de confusión. Por lo tanto no van a suponer una pérdida de precisión en la clasificación definitiva con la leyenda más general (Tabla 1).

#### Precisión de las aproximaciones 1-3-4 y 3-4-5

Al hablar de precisión de una clasificación nos referimos a errores de tipo temático y no de posicionamiento, esto es, resultado de la georreferenciación de la imagen. Una forma de separar estas dos fuentes de error es la propuesta por Warren et al. (1990): usar sólo áreas homogéneas alejadas de los límites de parcela para muestras puntuales. Teniendo en cuenta que el esquema de muestreo que hemos escogido es en conglomerados, la única forma de garantizar que cada unidad de muestreo o conglomerado pertenece a una única clase es limitar el muestreo a aquellos píxels cuya identidad no se ve influenciada por potenciales errores de registrado (Lillesand y Kiefer, 1994).

Para cada una de las dos aproximaciones calculamos sendas matrices de confusión. En esta fase de validación precisamos una medida independiente del acuerdo entre imagen clasificada y verdadterreno. Para ello usaremos las restantes parcelas verdad- terreno no utilizadas en la fase de entrenamiento. En este caso el esquema de muestreo ha sido en conglomerados, con bloques de 3(3 píxels. El número de datos de referencia ha sido de 279 para la clase Bar1, 423 para la clase Bar2, 171 para Cer1, 522 para Cer2, 306 para Cer3, 243 para Oli1, 666 para Vid1, y 594 para la clase Vid2. En las Tablas 4 y 5 presentamos las matrices de confusión resultantes normalizadas por el número total de datos de referencia. Estrictamente hablando el análisis de la matriz de confusión debería corresponder a un muestreo aleatorio simple y no en conglomerados. Pero tal y como indica Stehman (1997b) las expresiones de estimadores como Pc, F<sub>pi</sub>, F<sub>ui</sub>, k, k<sub>pi</sub> y k<sub>ui</sub> son las mismas para el muestreo aleatorio simple que para el muestreo en conglomerados.

A partir de los datos de estas matrices calculamos la precisión de las dos aproximaciones usando tanto la fiabilidad global como el coeficiente kappa. Para la aproximación 1-3-4 tenemos:  $P_c = 60\%$ y  $\kappa = 0.54\pm0.01$  con una probabilidad del 95%; y para la aproximación 3-4-5 estos valores son:  $P_c$  =65% y  $\kappa$  = 0,59±0,01, también con una probabilidad del 95%. Como era de esperar los resultados que proporciona el coeficiente ( son ligeramente inferiores a los dados por P<sub>c</sub>. Sin embargo no difieren en cuanto a que la aproximación 1-3-4 posee una fiabilidad un poco mejor que la 3-4-5.

También en las Tablas 4 y 5 figuran las fiabilidades del productor y del usuario para cada una de las clases. Estos valores junto con los valores de  $\kappa_{pi}$  y  $\kappa_{ui}$  de la Tabla 6 nos indican en cuál de las dos aproximaciones cada una de las clases ha sido clasificada con una precisión más elevada.

	Bar1	Bar2	Cer1	Cer2	Cer3	Vid1	Vid2	Xi+	Fui(%)
Bar1	0,03	0,018	0,0007	0,02	0,0011	0,0007		0,07	40
Bar2	0,0007	0,08	0,0004	0,004				0,08	94
Cer1		0,005	0,05	0,008	0,0007	0,008	0,03	0,10	50
Cer2	0,014	0,005		0,13				0,15	87
Cer3	0,0025	0,04	0,0018	0,0003	0,09	0,04	0,0007	0,17	52
Vid1		0,0021	0,004	0,0004	0,005	0,17	0,03	0,21	78
Vid2			0,0003			0,007	0,06	0,07	88
X+i	0,05	0,15	0,06	0,19	0,11	0,24	0,21		
Fpi(%)	54	53	87	69	85	70	28		

Tabla 4. Matriz de confusión normalizada por el número total de datos para la aproximación 1-3-4.

	Bar1	Bar2	Cer1	Cer2	Cer3	Oli1	Vid1	Vid2	Xi+	Fui(%)
Bar1	0,03	0,022	0,004	0,015		0,005	0,0003		0,07	36
Bar2	0,0003	0,08		0,0017	0,0007	0,003			0,09	94
Cer1		0,006	0,018	0,001	0,0003	0,0003	0,04	0,005	0,07	24
Cer2	0,02	0,0024		0,13					0,15	86
Cer3	0,0007	0,01	0,004	0,0003	0,08	0,001	0,018		0,12	71
Oli1	0,0017	0,01	0,007	0,001	0,01	0,019	0,012		0,06	31
Vid1		0,002	0,025	0,0003	0,004	0,003	0,14	0,03	0,20	67
Vid2							0,013	0,15	0,17	92
X+i	0,05	0,14	0,06	0,18	0,10	0,04	0,23	0,20		
Fpi(%)	50	60	31	70	82	53	60	76		

Tabla 5. Matriz de confusión normalizada por el número total de datos para la aproximación 3-4-5.

	Aproxima	Aproximación 1-3-4		ción 3-4-5
	Kpi	Kui	Кpi	Kui
Bar1	0,5	0,4	0,5	0,3
Bar2	0,5	0,9	0,6	0,9
Cer1	0,9	0,5	0,3	0,2
Cer2	0,6	0,8	0,6	0,8
Cer3	0,8	0,5	0,8	0,7
Oli1	-	-	0,5	0,3
Vid1	0,6	0,7	0,5	0,6
Vid?	0.2	0.8	0.7	0.0

**Tabla 6.** Coeficientes  $\kappa_{pi}$  y  $\kappa_{ui}$  para las categorías que intervienen en las aproximaciones 1-3-4 y 3-4-5.

#### Binomios aproximación-clase

De cada aproximación sólo algunas clases pasarán a formar parte del mapa final. El proceso de asignar a cada clase la mejor aproximación se ha llevado a cabo teniendo en cuenta que en el esquema de clasificación que hemos seguido no todas las clases tienen el mismo peso específico (nuestro objetivo es clasificar la vid de la zona) y que no pretendemos distinguir entre subclases, como por ejemplo entre vid joven o más desarrollada, sino que nos limitamos a la leyenda más general de la Tabla 1. Para poder favorecer la vid frente a las otras clases ha sido necesario analizar las propias matrices de confusión.

De la aproximación 1-3-4 tomaremos las siguientes clases: (1) Vid1, porque presenta una precisión más elevada para esta aproximación que para la 3- 4-5; (2) Bar1, porque apenas se confunde con las clases Vid1 y Vid2, y presenta valores de  $F_{pi}$  y  $F_{ui}$  ligeramente mejores; (3) Cer1, porque presenta valores bajos de confusión con las clases Vid1 y Vid2, la mayor confusión se da con la clase Cer3, y además los valores de  $F_{pi}$  y  $F_{ui}$  son bastante mejores que para la aproximación 3-4-5; y (4) Cer2, porque los resultados son prácticamente idénticos en ambas aproximaciones, y en ningún caso se confunde con las clases Vid1 y Vid2.

De la aproximación 3-4-5 tomaremos las siguientes clases: (1) Vid2, porque no se confunde con ninguna otra categoría, a excepción de la clase Vid1y además las fiabilidades Fpiy Fuison bastante más elevadas; (2) Bar2, porque no se solapa con las clases Vid1 y Vid2, la máxima confusión se da con la clase Bar1, que no supone ningún problema si pensamos en la clasificación definitiva, además de esto, el valor de Fp i es ligeramente mejor que para la aproximación 1-3-4; Cer3, porque si bien en ambas aproximaciones presenta valores muy bajos de confusión con las clases Vid1 y Vid2, sin embargo en esta aproximación se confunde menos con la clase Bar2 que en la aproximación 1-3-4; y (4) Oli1, es este caso, sólo hemos contemplado la aproximación 3-4-5.

Resumiendo, en la aproximación 1-3-4 se han clasificado con una precisión más elevada las clases: Barl, Cerl, Cer2 y Vidl. Mientras que en la aproximación 3-4-5 estas clases son: Bar2, Cer3 y Vid2. Queremos señalar que las clases Bar1, Cer1, Cer2 y Vid1 presentan una extensión sobre el mapa bastante mayor que las clases Bar2, Cer3, Oli1 y Vi d 2.

## CLASIFICACIÓN DEFINITIVA

La clasificación definitiva resulta de las dos anteriores tomando como base la aproximación 1-3-4 y sustituyendo en ésta los píxels clasificados como Bar2, Cer3, Oli1 y Vid2 en la aproximación 3-4-5. A continuación agrupamos estas ocho clases en las clases más generales de Barbecho, Cereal, Olivo y Vid. Finalmente aplicamos un filtro modal para eliminar los píxels aislados y poco significativos que salpican algunas de las parcelas. El resultado es el mapa que se muestra en la Figura 2.

El porcentaje de ocupación de las distintas cubiertas nos aporta una primera estimación de la precisión del mapa. La Tabla 7 contiene estos porcentajes (también traducidos a hectáreas) sin incluir los píxels con nubes. La falta de un inventario sobre los cultivos de esta zona en 1994 nos impide validar estos resultados con los de otras fuentes. Pero, al igual que sucedía con las aproximaciones 1-3-4 y 3-4-5, sí podemos tener una estimación cuantitativa de la precisión del mapa definitivo a partir de la matriz de confusión. Usando las mismas muestras de verificación que en el apartado anterior calculamos la matriz de confusión (Tabla 8) y los coeficientes kappa (Tabla 9), esta vez para la leyenda más general de la Tabla 1. La precisión del mapa de la Figura 2 viene dada por unos valores de Pc= 85% y  $\kappa$  = 0,83±0,01, con una probabilidad del 95%. En comparación con los valores de Pc = 60% y  $\kappa$  = 0,54±0,01 para la aproximación 1-3-4 y de Pc= 65% y  $\kappa$  = 0,59±0,01 para la aproximación 3-4-5. A nivel de categorías, la metodología seguida ha redundado en una mejora sustancial de la precisión para la categoría Vid, con un 91% de las áreas correctamente clasificadas, y un 93% de los píxels clasificados como Vid que corresponden realmente a Vid.



Figura 2. Clasificación del viñedo en la zona de Tomelloso en junio de 1994

	Ocupación suelos 1994		
	(ha)	(%)	
Barbecho	1351	18	
Cereal	2161	28	
Olivo	240	3	
Vid	3869	51	

Tabla 7. Ocupación de usos de suelo en % y en hectáreas resultado de la clasificación final de la zona de Tomelloso para junio de 1994.

	Barbecho	Cereal	Olivo	Vid	Xi+	Fui(%)
Barbecho	0,16	0,04	0,005	0,004	0,21	77
Cereal	0,015	0,24		0,03	0,29	84
Olivo	0,011	0,004	0,016	0,007	0,04	42
Vid		0,03	0,001	0,4	0,43	93
X+i	0,19	0,3	0,02	0,44		
Fpi(%)	84	80	80	91		

Tabla 8. Matriz de confusión normalizada por el número total de datos de referencia para la clasificación final.

	Крі	Kui
Barbecho	0,8	0,7
Cereal	0,7	0,8
Olivo	0,8	0,4
Vid	0,8	0,9

Tabla 9. Coeficientes  $\kappa_{pi}$  y  $\kappa_{ui}$  para las categorías más generales inventariadas en la clasificación final.

# CONCLUSIONES

Las principales conclusiones que se desprenden de este trabajo son:

- Si la selección de las muestras de entrenamiento es correcta, entonces la distancia de Bhattachary ya es un buen criterio para maximizar la separabilidad de clases en términos de las bandas a usar en la clasificación.
- Utilizar más de una combinación de bandas TM para clasificar aquellas categorías discernibles permite aumentar la precisión de la clasificación final cuando no se dispone de información adicional del tipo multi-estacional a través de más de una imagen de la zona.
- El aumento de la precisión también va asociado a una pérdida de información en la leyenda del mapa.
- Tanto las fiabilidades global, del usuario y del productor como los diferentes coeficientes kappa han servido de criterio para buscar la relación óptima entre clase y combinación de bandas. Los resultados aportados por ambos grupos de estimadores son muy similares y en términos relativos, idénticos.
- Ahora bien, si lo que se desea es favorecer la precisión de una clase frente a las otras, entonces la matriz de confusión aporta más información que los coeficientes de fiabilidad y kappa.
- Hemos clasificado la Vid de la zona de Tomelloso en junio de 1994 con una fiabilidad del productor del 91% y una fiabilidad del usuario del 93%.

## AGRADECIMIENTOS

Los autores desean expresar su gratitud al Profesor Francisco Montero por su colaboración en la obtención de la información verdad-terreno, y a la Universidad de Castilla-La Mancha por la financiación aportada a través del proyecto "Determinación de la evapotranspiración diaria en la zona de Tomelloso (Ciudad Real) a partir de imágenes NOAA AVHRR y Landsat-TM" en el marco del proyecto europeo EFEDA II (Ref: EV5V-CT93-0272).

# **BIBLIOGRAFÍA**

- BARTH, H.-K., y RUNGE, J. 1992. Land use and vegetation of the pilot areas of the EFEDA project La Mancha, Spain. University of Paderborn, Germany.
- BISHOP,Y., FIENBERG, S., y HOLLAND, P. 1975. Discrete multivariate analysis-Theory and practice. Cambridge, MA. MIT Press.
- BOLLE, H.-J., y STRECKENBACH, B. Eds. 1993. *The Echival Field Experiment in a Desertificationthreatened Area (EFEDA)*. Final Report. Berlin. EFEDA Secretariat.
- BRENNAN, R., y PREDIGER, D. 1981. Coefficient kappa: some uses, misuses and alternatives. *Educational and Psychological Measurement*. 41: 687-699.
- CHUVIECO, E. 1990. Fundamentos de teledetección espacial. Madrid. Rialp, 453 p.
- DICKS, S.E., y LO, T.H.C. 1990. Evaluation of thematic map accuracy in a land-use and land-cover mapping program. *Photogrammetric Engineering and Remote Sensing*. 56: 1247-1252.
- JANSSEN, L.L.F., y VAN DER WEL, F.J.M. 1994. Accuracy assessment of satellite derived land-cover data: a r ev i ew. *P h o t og rammetric Engineering and Remote Sensing*. 60: 419-426.
- LANJERI, S. 1996. Estudio y seguimiento por teledetección del viñedo de la zona experimental EFEDA (Castilla-La Mancha). Tesina de Licenciatura. Univ. De Valencia.
- LILLESAND, T., y KIEFER, R. 1994. *Remote sensingand image interpretation*. New York. John Wiley & Sons, Inc.
- MOISEN, G. G., EDWARDS, T.C., Jr., y CUTLER, D. R. 1994. Spatial sampling to asses classification accuracy of remotely sensed data. En *Environmental information management and analysis: Ecosystem to global scales*. New York. Taylor and Francis.
- STEHMAN, S. V. 1997a. Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*. 62: 77-89.
- STEHMAN, S. V. 1997b. Estimating standard errors of accuracy assessment statistics under cluster sampling. *Remote Sensing of Environment*. 60: 258-269.
- STORY, M. Y CONGALTON, R. 1986. Accuracy assessment: a user's perspective. *Photogrammetric Engineering and Remote Sensing*. 52(3): 397-399.
- RICHARDS, J. A. 1986. *Remote sensing digital image analysis*. London. Springer-Verlag. 206-225.
- WARREN, S., JOHNSON, M., GORAN, W. y DIERSING, V. 1990. An automated, objective procedure for selecting representative field sample sites. *Photogrammetric Engineering and Remote Sensing*. 56(3): 333-335.