

## COMPARACIÓN DE DISTINTOS MÉTODOS DE CLASIFICACIÓN PARA LA DISCRIMINACIÓN DE CULTIVOS DE REGADÍO

V. CACHORRO (\*), A. J. BERJÓN (\*), A. GUERRERO (\*\*) y J. CID (\*\*)

chiqui@baraja.opt.cie.uva.es

(\*) *Grupo de Óptica Atmosférica. Departamento de Óptica y Física Aplicada. Facultad de Ciencias, Valladolid*  
(\*\*) *Grupo de Tratamiento de la Señal y Datos, Escuela Politécnica superior, Universidad Carlos III de Madrid*

**RESUMEN.** En el presente trabajo se pretende conocer el comportamiento de distintos métodos de clasificación de imágenes ante el problema de diferenciar distintos cultivos de regadío utilizando solamente sus características de reflectividad espectral a lo largo de su evolución. Los métodos aplicados serán: clasificación mediante una Red neuronal de perceptrones, clasificación por máxima verosimilitud, y clasificación por mínima distancia. La zona de estudio se refiere básicamente a la provincia de Valladolid, en donde los cultivos de regadío más importantes son la remolacha, el maíz, la patata, y la alfalfa, y son a estos cuatro cultivos de regadío a los que se les va a prestar un mayor interés. Ello no obsta para que en el proceso de esta clasificación no se hayan discriminado otros usos, como cultivos de secano, arboleda, bosque, agua, etc. El porcentaje final de aciertos para cada método es del 96.4%, 93.4% y 90.4%.

**ABSTRACT.** In the present work we try to be familiar with the behaviour of different image classification methods in order to discriminate cultures of irrigated land, with the only use of their spectral reflectivity characteristics and their evolution through the time. The applied methods are Classification by a Neuronal Network of perceptrons, Maximum Likelihood Classification, And the Minimum Distance Classification. The zone of study is basically the province of Valladolid, where the most important cultures of irrigated land are sugar beet, maize, potato, and alfalfa, and therefore our strong interest in these four irrigated cultures. Nevertheless we'll also discriminate another components of land use, like cultures of dry land, woods, forest, water, etc. The final percentages of successful results in each method are 96.4%, 93.4% and 90.4% respectively.

**Palabras claves:** clasificación, muestreo, discriminación, regadío, red neuronal, máxima verosimilitud.

### INTRODUCCIÓN

La utilización de distintos métodos para la clasificación de imágenes captadas por satélite tiene ya una amplia trayectoria. Sin embargo en la mayor parte de trabajos, las distintas clases que se pretenden discriminar sobre la imagen suelen ser demasiado genéricas y de características bastante bien definidas. En el presente trabajo pretendemos conocer el comportamiento de estos métodos al ser aplicados a una serie de imágenes, en las que se intenta localizar y discriminar diversos cultivos de regadío, de similares características, tales como remolacha, maíz, patata y alfalfa.

### ÁREA DE ESTUDIO

La zona seleccionada para realizar el estudio consta de aproximadamente 8000 km<sup>2</sup>, situados en la zona centro de la Comunidad de Castilla y León, que correspon-

de básicamente a la provincia de Valladolid, en la cual las principales zonas de cultivo de regadío se concentran alrededor de las márgenes de los ríos Duero y Pisuerga. Las producciones de estos cultivos de regadío presentan actualmente una gran variación dependiendo de las ayudas de la PAC.

### OBTENCIÓN Y PREPROCESADO DE LAS IMÁGENES

En este caso, las imágenes Landsat TM son las elegidas como base del trabajo, por llegar estas a un compromiso entre información tanto espacial (30m por píxel), temporal (20 días) como espectral (6 bandas entre el visible y el infrarrojo medio: 485, 560, 660, 830, 1650, 2215 nm), y de coste. Este sensor dispone además de una séptima banda en el infrarrojo térmico (11450 nm) con una resolución espacial de 120 m, que aunque

no ha sido utilizada como tal para la clasificación, sí se ha utilizado para depurar las imágenes de nubes.

De toda la campaña, debido a las condiciones meteorológicas especialmente adversas solo pudimos seleccionar las imágenes de tres fechas: 19-08-99, 18-07-99 y 04-13-99. De estas, la imagen de julio se encuentra prácticamente despejada de nubes, sin embargo, las otras dos imágenes presentan un 30% de superficie oculta por nubosidad. Dado que nos interesa utilizar la información de las tres imágenes simultáneamente, el primer paso en el preprocesado ha de ser la georreferenciación de las imágenes. Esto se ha realizado utilizando cartografía digital, en coordenadas UTM. Se han empleado 100 puntos de control en un ajuste polinómico de segundo grado junto con el método del vecino más próximo (Prados, 1995). Así mismo se han eliminado aquellos puntos que en alguna de las tres imágenes estuvieran ocultos por nubes. Para esto se ha tomado un criterio simple de cumplimiento de dos condiciones: valores bajos en la banda del infrarrojo térmico, y altos en el visible.

### SELECCIÓN DE MUESTRAS

Clases	Píxeles	Hectáreas
Agua	436	39
Arboleda de hoja caduca	150	14
Arboleda de hoja perenne	20264	1826
Baldío	7809	703
Barbecho	146	13
Cultivos de Secano	883	80
Cultivos de Regadío	1774	160
Urbano	2834	255

Tabla 1. Clases Base.

Clases	Píxeles	Hectáreas
Alfalfa	155	14
Maíz	718	65
Patata	100	9
Remolacha	801	72

Tabla 2. Clases de Cultivos de Regadío

Dado que los métodos utilizados están dentro de los conocidos como supervisados, es necesario partir de una serie de muestras de cada una de las clases en las que queremos dividir nuestra imagen. En nuestro caso el proceso de toma de muestras se realizó mediante un muestreo en campo con ayuda de GPS, salvo para las clases "Urbano", "Baldío", y "Arboleda de hoja perenne" que debido a su fácil identificación, se tomaron directamente sobre la imagen. En la Tabla 1 se puede ver

las clases base en que hemos dividido la imagen, y el número de muestras para cada uno. A su vez la clase "Cultivos de Regadío" se subdividió en las clases que se muestran en la Tabla 2. Estas muestras se utilizarán tanto para definir la regla de discriminación, como para verificar la clasificación una vez realizada.

El Proceso de clasificación lo dividimos en dos fases. En la primera, utilizando la información de las tres imágenes, asignamos a cada píxel una de las clases de la tabla 1. Incluimos en esta fase la clase "alfalfa" por ser esta fácilmente separable del resto de cultivos de regadío utilizando la imagen de abril. En la segunda fase, clasificamos como "maíz", "patata" o "remolacha" cada uno de los píxeles clasificados como "Cultivos de Regadío" en la primera fase. En este caso, la clasificación se lleva a cabo únicamente con la información de las imágenes de julio y agosto, ya que en esta fecha no hay cubierta vegetal y su uso distorsionaría los resultados.

Hemos de mencionar la importancia del trabajo de campo en la toma de muestras para el caso de una discriminación fina de cultivos, como la que aquí se pretende, habida cuenta que estos son altamente interferenciales entre sí, desde el punto de vista de su reflectancia espectral.

### MÉTODOS DE CLASIFICACIÓN APLICADOS

En este trabajo se ha empleado un método basado en una red neuronal y dos métodos estadísticos: el método de máxima verosimilitud o "maximum likelihood" y el método de mínima distancia. Estos dos últimos se han llevado a cabo utilizando el sistema de procesado de imágenes ENVI (Environment for Visualising Images), mientras que en el caso de la red neuronal se viene desarrollando un software propio (Guerrero y Cid 2000).

### RED NEURONAL DE PERCEPTRONES

La arquitectura de la red neuronal desarrollada es la que se muestra en la Figura 1. A partir de un vector de entrada (representado por  $x$ ), la red determina la clase a la que corresponde ese vector.

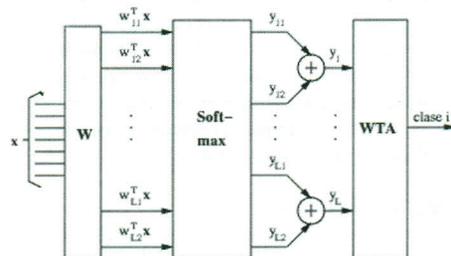


Figura 1. Arquitectura de la red neuronal.

$w_{ij}$  representa el vector de pesos del perceptrón  $j$  de la clase  $i$ . Los perceptrones están agrupados por la clase a la que pertenecen. En total hay  $L$  clases, y cada una está formada por  $n_j$  perceptrones. A diferencia de otras redes neuronales, en este caso, las salidas de los perceptrones están acopladas por una función de activación no lineal denominada «softmax». La función «softmax» garantiza que las componentes del vector de decisión suave son no negativas y suman 1, pudiendo de este modo representar probabilidades. Las salidas de esta función se obtienen de la siguiente forma:

$$y_{ij} = \frac{\exp(w_{ij}^T \mathbf{x})}{\sum_i \sum_m \exp(w_{im}^T \mathbf{x})}$$

Las  $y_{ij}$  correspondientes a una misma clase son sumadas para obtener las  $y_i$  (representa la probabilidad de que un vector de entrada a la red pertenezca a la clase  $i$ ). Después, se aplica el criterio WTA (*Winner Take All*), que calcula la clase para la que  $y_i$  es máxima y asigna dicha clase al vector de entrada a la red.

El entrenamiento de la red se realiza mediante el algoritmo de descenso por gradiente estocástico en el espacio de los pesos de la red (Bishop, 1995) para minimizar una cierta función de coste conocida como «entropía relativa»:

$$C(\mathbf{y}, \mathbf{d}) = \sum_{i=1}^L -d_i \log y_i$$

donde  $\mathbf{y} = (y_1, \dots, y_L)$  es la salida de la red,  $\mathbf{d} = (d_1, \dots, d_L)$  es la etiqueta asociada a  $\mathbf{x}$ :  $d_i = 1$  si  $\mathbf{x}$  pertenece a la clase  $i$ , y  $d_i = 0$  si no pertenece. Además, el número de perceptrones necesarios para cada clase se calcula dinámicamente durante el entrenamiento.

Se puede demostrar (Richard y Lippmann, 1991), que minimizando la entropía relativa, las  $y_i$  obtenidas son estimaciones de las probabilidades a posteriori de las clases,  $y_i \approx p(i/x)$ . Esas probabilidades a posteriori además de servirnos como medida de fiabilidad de la clasificación, nos permiten mejorar esa clasificación (postprocesado) realizando un filtrado espacial del mapa de probabilidades obtenido a partir de la información proporcionada por los vecinos de cada pixel de la imagen.

#### MÉTODO DE MÁXIMA VEROSIMILITUD Y MÉTODO DE LA MÍNIMA DISTANCIA

No nos detendremos en un análisis detallado de estos dos métodos por estar ya ampliamente descritos en la bibliografía (Gandía y Meliá, 1991; Richards y Jia, 1999). Sin embargo nos gustaría hacer notar que aún siendo el método de máxima verosimilitud el método estadístico más aceptado para la clasificación de imágenes,

depende en un alto grado del número de muestras que tengamos disponibles para determinar con suficiente precisión tanto la media como la matriz de covarianza. En el caso de tener un número reducido de muestras, puede llegar a ser preferible recurrir a otro tipo de métodos, como el de mínima distancia, siendo este el motivo de utilizar un método que aparentemente es mucho más débil.

#### RESULTADOS

Una vez realizados los tres procesos de clasificación que acabamos de describir, proseguimos con un análisis mediante varios indicadores de la bondad de nuestras clasificaciones. Para su cálculo, como ya indicamos anteriormente, hemos mantenido reservadas sin utilizar en la clasificación, aproximadamente la mitad de las muestras. A partir de estas, calculamos las matrices de confusión, que mostramos en las Tablas 5, 6 y 7. Estos resultados hacen referencia exclusivamente a los cultivos de regadío.

	Alfalfa	Maíz	Patata	Remolacha
No clas.	0	0	0	0
Alfalfa	100	0.51	0	0
Maíz	0	82.27	0	1.51
Patata	0	0	100	0
Remolacha	0	17.22	0	98.49

Tabla 3. Matriz de confusión según el método de la mínima distancia

	Alfalfa	Maíz	Patata	Remolacha
No clas.	0	0.51	0	0
Alfalfa	100	0	0	0
Maíz	0	93.85	0	9.05
Patata	0	0	100	0
Remolacha	0	5.64	0	90.95

Tabla 4. Matriz de confusión según el método de máxima verosimilitud

	Alfalfa	Maíz	Patata	Remolacha
No clas.	0	2.56	0	0
Alfalfa	100	0	0	0
Maíz	0	95.14	0	17.34
Patata	0	0.51	100	0
Remolacha	0	1.79	0	82.66

Tabla 5. Matriz de confusión según el método de la red neuronal

Como un primer resultado, el tanto por ciento de píxeles que han sido bien clasificados de las muestras que tene-

mos reservadas es en este caso de 96.4%, 93.4% y 90.4% respectivamente para las clasificaciones por red neuronal, máxima verosimilitud y mínima distancia. Otros indicadores comúnmente aceptados son tanto los errores de comisión, como las precisiones del productor y

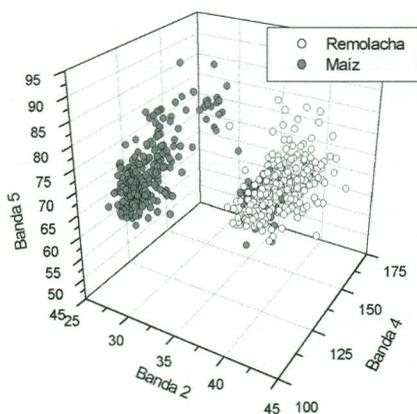
del usuario. En la Tabla 6, podemos ver los resultados para las tres clasificaciones. Damos para finalizar el coeficiente Kappa (Lotsch, 1996), gracias al cual, se consigue de forma concentrada Red Neuronal Máxima verosimilitud Mínima distancia

	Comis.	Pr.Prod.	Pr.Us.	Comis.	Pr.Prod.	Pr.Us.	Comis.	Pr.Prod.	Pr.Us.
Alfalfa	0.00	100.0	97.5	0.00	100.0	100.0	0.00	100.0	100.0
Maíz	9.23	93.8	98.2	0.02	93.9	91.1	0.04	95.1	84.3
Patata	0.00	100.0	100.0	0.00	100.0	100.0	0.01	100.0	96.1
Remol.	5.53	91.0	85.4	0.01	91.0	94.3	0.01	82.7	97.9

**Tabla 6.** Errores de comisión y precisiones del productor y del usuario.

mucha información, al incluir datos tanto de las filas como de las columnas de la matriz de confusión. Los valores obtenidos son 0.942, 0.894 y 0.846 respectivamente para cada método.

Observando las matrices de confusión de las tablas anteriores, el resultado del 100% para la alfalfa es lógico, pues como ya comentamos, para su discriminación utilizamos las tres imágenes, mientras que para el resto de cultivos de regadío sólo hemos usado las de Julio y Agosto. Sin embargo el resultado del 100% para la patata es bastante extraño, debido a su difícil discriminación con el maíz y la remolacha, sobre todo con esta última. Esto puede ser debido a un número insuficiente de muestras, pues estas eran mucho menores que las tomadas tanto para la remolacha, como para el maíz. Otra posible causa puede ser debida a que el ciclo fenológico de la patata es más temprano en nuestra zona de estudio, y que esto halla quedado reflejado en la información de Julio y Agosto.



Uno de los resultados más destacables, es la difícil discriminación entre los cultivos de maíz y de remola-

cha. Esto viene determinado por la proximidad de las distribuciones que definen estas dos clases, así como por la gran dispersión de la clase "Maíz" (Figura 2).

## CONCLUSIONES

Los resultados son bastante satisfactorios y podemos decir, que concuerdan con la idea inicial de que los métodos más robustos, como el método de máxima verosimilitud, pero sobretudo el de la red neuronal, son los que consiguen unos mejores resultados.

## BIBLIOGRAFÍA

- BISHOP, C. M., 1995: "Neural Networks for Pattern Recognition". *Oxford University Press*.
- GANDÍA, S. A. y J. MELIÁ (Editores), 1990: "La Teledetección en el Seguimiento de los Fenómenos Naturales". Recursos Renovables: Agricultura. Universitat de Valencia.
- GUERRERO, A., y J. CID SUEIRO, 2000: «Estimating Posterior Probabilities for Terrain Classification with a Softmax-based Neural Network». *The EOS/SPIE Symposium on Remote Sensing 2000*, Barcelona.
- LOTSCH, A., 1996: "Biome level classification of land cover at continental scales using decision trees". Vordiplom, Free University of Berlin.
- PRADOS, M. J., 1995: "Teledetección y agricultura". Ministerio de agricultura, pesca y alimentación. Secretaría general técnica.
- RICHARD, M. D., y R. P. LIPPMANN, 1991: «Neural network classifiers estimate Bayesian a posteriori probabilities». *Neural Comput.*, vol. 3, no. 4, pp. 461-483.
- RICHARDS, J. A., y X. JIA, 1999: "Remote sensing digital image analysis". Third, revised and enlarged edition. Springer.

## AGRADECIMIENTOS

Este trabajo se ha realizado dentro de un proyecto por artículo 11 de la UVA y la empresa GRAFOS.