

METODOLOGÍA PARA LA BÚSQUEDA DEL MEJOR CLASIFICADOR DE IMÁGENES DE SATÉLITE

R. M. AYALA (*) y M. MENENTI (**)

rmayala@ual.es

(*) Dept. Lenguajes y Computación. Universidad de Almería.
04120 La Cañada, Almería, Spain

(**) DLO Winand Staring Centrum for Integrated Land,
Soil and Water Research (SC-DLO). P.O. Box 125,
6700 AC Wageningen, Netherlands

RESUMEN: En tratamiento digital de imágenes la calidad de los resultados obtenidos por un proceso de clasificación va a estar determinada por una serie de factores relacionados con el conjunto de entrenamiento y con un grupo de parámetros asociados a dicho proceso de clasificación. En este trabajo se presenta una metodología para la obtención automatizada del *mejor clasificador* asociada a una imagen, a partir de una colección de potenciales clasificadores. Para este propósito, se propone una técnica de selección del clasificador más óptimo, donde se evalúan las características de *separabilidad* del conjunto de entrenamiento y la *calidad* y *confiabilidad* de los diferentes tipos de clasificadores que se pueden aplicar a una imagen de satélite. El mejor clasificador seleccionado de la colección de clasificadores candidatos es aquel que maximiza el valor final de dichos parámetros.

ABSTRACT: In digital remote sensing the quality of the results obtained by a classification process will be determined by a series of factors. These factors are related to the training set and group of parameters associated to the classification process. In this job a methodology is presented to obtain the better classifier associated to an imagen, from a collection of potential classifiers. For this purpose, we propose a technique of selection of the best classifier. Here it is evaluated the separability of the training set and the accuracy and reliability of the classifiers that can be applied to a satellite image. The best selected classifier in the collection of classifiers candidates is that maximizes the final value of these parameters.

Palabras clave: teledetección, conjunto de entrenamiento, clasificador, imagen de satélite, rendimiento

INTRODUCCIÓN

El objetivo final en la mayoría de los procesos de tratamiento digital de imágenes es la división de la imagen original en un número finito de clases disjuntas, donde cada uno de los píxeles que componen la imagen es asignado a una clase en particular. Este proceso es conocido como clasificación digital de imágenes y ha sido objeto de estudio desde hace varias décadas.

En la actualidad se han desarrollado un gran número de clasificadores de sencillo manejo para el usuario que se han ido incorporando a los paquetes comerciales de tratamiento digital de imágenes, como Erdas Imagine o Idrisis, entre otros. Los resultados proporcionados por estos métodos de clasificación difieren unos de otros. Sus resultados dependen fundamentalmente del conjunto de muestras seleccionado para entrenar al clasificador y del método de clasificación escogido, además de las características de la imagen (Jähne, 1997).

Resulta prácticamente imposible conocer a priori el clasificador que proporciona los resultados más fiables para la clasificación de una imagen determinada. Ante tal situación, surge la necesidad de incorporar un método que de forma automática localice y muestre el clasificador que proporcionará los mejores resultados.

Entre las familias de clasificadores más extendidas en la mayoría de los paquetes comerciales de tratamiento digital de imágenes, destaca aquella que únicamente se basa en la información individual de cada píxel, denominada *reconocimiento espectral de patrones*.

En este artículo se propone una metodología para automatizar la elección del clasificador de mayor rendimiento en un proceso de clasificación de imágenes de satélite, basándose en *reconocimiento espectral de patrones*.

En reconocimiento espectral de patrones se usan dos aproximaciones diferentes (Duda y Hart, 1973):

Clasificación Supervisada

Esta clasificación se caracteriza fundamentalmente por la necesidad por parte del usuario de definir con la máxima precisión cada una de las categorías que éste pretende discriminar, antes de efectuar la clasificación. Estas categorías también se puede determinar a partir de un programa que calcule las concentraciones de clusters similares. Esta primera fase se denomina *fase de entrenamiento*, y en función del método utilizado para escoger las muestras, puede ser supervisada o no supervisada (Castleman K., 1996).

Una vez formado el conjunto de entrenamiento, el siguiente paso consiste en la elección del clasificador que se va a aplicar a la imagen. Existen numerosas alternativas, cuyos resultados diferirán unos de otros. Esta elección está en función de una serie de parámetros y características de la imagen objeto de estudio.

Independientemente del clasificador aplicado, el proceso de clasificación supervisada consiste en la asignación de los píxeles de la imagen a una de las categorías formadas en la fase de entrenamiento. Un píxel se asignará a una clase cuando satisfaga el conjunto de criterios relacionados con esa clase.

Clasificación No Supervisada

Para realizar este tipo de clasificación no es necesario un conocimiento previo del área de estudio por parte del analista que va a realizar la clasificación, aunque éste tendrá la misión de interpretar las clases que son generadas a partir de dicha clasificación. Este proceso consiste fundamentalmente en la elección automatizada de las diferentes clases que componen la imagen.

El proceso de agrupamiento consiste en formar colecciones de píxeles, de forma que cada píxel de la imagen sea asignado a uno de esos grupos. Isodata es el algoritmo más utilizado para el proceso de clasificación no supervisada (Chuvieco, 1990).

METODOLOGÍA

La metodología propuesta, aplica y valida el conjunto de clasificadores —ya incorporados en el paquete de tratamiento digital de imágenes— y el conjunto de muestras diseñado en la fase de entrenamiento.

Para el desarrollo del algoritmo propuesto hemos utilizado el lenguaje de programación C, junto a una serie de librerías de herramientas C que lleva incorporado el programa de tratamiento digital de imágenes Erdas Imagine. En la tabla 1 se muestra parte de dicho algoritmo.

```
Procedure BestClassifier (in muest, in image,
out IPmax, out superMax, out nosuperMax)
  while (nosuper<opcionesIsodata) do
    call isodata job (in muest, in image,
      out conjmuest, out nosuper)
  while (super<totalClasificadores) do
    call supervised job (in image, in conjmuest,
      out imagclass, out super, out distance)
    call separability función (conjmuest)
    call reliability función (distance)
    call accuracy función (conjmuest, imagclass)
    call IP función (separability, reliability,
      accuracy)
  if (IP>IPmax) then
    IPmax:=IP
    superMax:=super
    nosuperMax:=nosuper
  endif
endwhile
endwhile
End BestClassifier.
```

Tabla 1. Algoritmo de la metodología propuesta.

El proceso *BestClassifier*, anteriormente presentado, es un proceso que localiza el mejor clasificador entre una colección de clasificadores ya existentes, y que requiere dos parámetros en su entrada: un conjunto de muestras definidas previamente por el usuario (*muest*) y una imagen de satélite (*image*), que es la imagen objeto de estudio. Como parámetros de salida, *BestClassifier* devuelve tres parámetros: un indicador de rendimiento (*Ipmax*), el número de la iteración de la clasificación supervisada (*superMax*) y la no supervisada (*nosuperMax*) que corresponden al mejor clasificador.

Evaluación del mejor clasificador (IP)

Para determinar la eficacia del mejor clasificador, nos basamos en tres características: la separabilidad del conjunto de entrenamiento (*separability*), y la calidad (*accuracy*) y confiabilidad (*reliability*) del clasificador.

1.- **Separabilidad.** Calcula la distancia espectral entre dos muestras dentro del conjunto de entrenamiento. Esta medida evalúa la homogeneidad de las muestras escogidas para entrenar al clasificador. Suponiendo que los datos considerados están normalmente distribuidos y homogéneos, se ha estimado una mayor efectividad (Swain y King, 1973) en la distancia de Jeffries-Matusita (*JM*) para estimar la divergencia. La fórmula utilizada para su cálculo es:

$$JM_{ij} = \sqrt{2(1 - e^{-\alpha})}$$

$$\alpha = \frac{1}{8}(U_i - U_j)^T \left(\frac{C_i + C_j}{2} \right)^{-1} (U_i - U_j) + \frac{1}{2} \text{Ln} \left(\frac{(|C_i + C_j|/2)}{\sqrt{|C_i| |C_j|}} \right)$$

donde,

i, j = Muestras a comparar

C_i = Matriz de covarianza de la muestra i

U_i = Vector media de la muestra i

Ln = la función del logaritmo

$|C_i|$ = determinante de C_i

La situación ideal se presentará con un valor de la separabilidad igual a 1.414, indicando con esto que las muestras son totalmente separables.

2.- **Calidad.** Medida que nos indica la similitud existente entre las muestras del conjunto de entrenamiento y las categorías formadas en la imagen final clasificada. Este valor se obtuvo calculando la fracción de píxeles clasificados para cada clase en el archivo de referencia y la fracción de píxeles obtenidos para cada clase en el archivo resultante del proceso de clasificación.

Calidad = $1 - \varepsilon$

donde, $\varepsilon = \sum \varphi_i$ tal que:

$$\varphi_i = \begin{cases} 0 & \text{si } \gamma_i \leq 0 \\ \frac{\gamma_i}{\omega_i} & \text{si } \gamma_i > 0 \end{cases}$$

siendo,

$$\omega_i = \sum A_i^{\text{ref}} - A_i^{\text{ref}}$$

$$\gamma_i = A_i^{\text{cl}} - A_i^{\text{ref}}$$

En este caso A_i^{ref} es la fracción de píxeles clasificados en la clase i del archivo de muestras de referencia y A_i^{cl} es la fracción de píxeles clasificados en la clase i de la clasificación resultante.

El rango de valores para la calidad oscila entre 0 y 1. La situación ideal se presenta cuando ε tome el valor 0, en cuyo caso esto indica que todos los píxeles de la imagen clasificada coinciden con el conjunto de muestras utilizado para entrenar al clasificador.

3.- **Confiabilidad** (D'Urso y Menenti, 1996). Indica la probabilidad de que un píxel pertenezca a la clase a la que ha sido asignado. Esta medida se calculó como

la integral de la curva obtenida dibujando la fracción de píxeles clasificados versus el nivel de confianza. El valor ideal de esta medida es igual a 1, ya que coincide con el área máxima de la curva. En la siguiente fórmula, el parámetro A se corresponde con el área máxima de la curva ($A=1$).

$$\text{Area} = \frac{\int_0^1 A(s) ds}{A}$$

Las tres medidas anteriores (separabilidad, calidad y confiabilidad) han sido utilizadas para calcular el indicador de rendimiento. Este nos va a indicar la calidad del clasificador.

El **indicador de rendimiento (IP)** se ha calculado con la siguiente fórmula (Azzali y Menenti, 1996):

$$IP = \frac{(\text{Sep} * \text{Sep}_{\text{ref}}) + (\text{Cali} * \text{Cali}_{\text{ref}}) + (\text{Confi} * \text{Confi}_{\text{ref}})}{(\text{Sep}_{\text{ref}}^2 + \text{Cali}_{\text{ref}}^2 + \text{Confi}_{\text{ref}}^2)}$$

donde, Sep_{ref} se corresponde con la separabilidad máxima (un valor igual a 1.414), Cali_{ref} es la calidad máxima (un valor igual a 1) y por último $\text{Confi}_{\text{ref}}$ es la confiabilidad máxima (valor de 1).

Este indicador de rendimiento calculado para un clasificador se lleva a cabo de forma reiterada para toda la colección de clasificadores iniciales y para las diferentes combinaciones de parámetros posibles. Finalmente el usuario obtendrá aquella combinación que presente el IP máximo.

RESULTADOS

El algoritmo propuesto se puede aplicar a cualquier imagen susceptible de ser clasificada con el paquete de tratamiento de imágenes Erdas Imagine. Una de las imágenes utilizadas para la evaluación de los resultados ha sido una imagen Landsat TM que corresponde a la zona del poniente de la provincia de Almería. En la figura 1 se muestra un ejemplo de esta imagen como resultado del clasificador y el conjunto de parámetros que maximizan el indicador de rendimiento.

El **conjunto de entrenamiento** correspondiente al indicador de rendimiento (IP) máximo se ha obtenido con una clasificación no supervisada, con 6 iteraciones de proceso y con un valor de 0.25 para el umbral de convergencia. Este valor de umbral indica que el procesamiento se detendrá cuando el 25% de los píxeles permanezcan inalterados entre una iteración y la siguiente.

El clasificador supervisado que ha hecho máximo el índice de rendimiento ha sido un **clasificador de máxi-**

ma probabilidad como regla paramétrica. Como regla no paramétrica se ha utilizado el clasificador de *paralelepípedos*. Para los píxeles no clasificados y para los que presentan superposición se ha hecho uso de la regla paramétrica.

A modo de análisis comparativo, en la tabla 2 se enfrentan los resultados de los factores de evaluación (separabilidad, calidad, confiabilidad e indicador de rendimiento) de dos clasificadores: uno corresponde al mejor clasificador detectado, y el otro a un clasificador con resultados menos óptimos. Las diferencias existentes entre los resultados obtenidos por ambos clasificadores se pueden observar en las figuras 1 y 2.

Factores	Mejor IP	IP bajo
Separabilidad	1,36	1,36
Calidad	0,93	0,83
Confiabilidad	0,96	0,86
Indicador	0.95	0.90

Tabla 2. Resultados obtenidos con el mejor clasificador y otro clasificador menos óptimo.




Figura 1. Mejor clasificador.




Figura 2. Clasificador de bajo rendimiento.

CONCLUSIÓN Y TRABAJOS FUTUROS

Los resultados de este trabajo demuestran la importancia que tiene la utilización de un método para la búsqueda del mejor clasificador y de los parámetros más apropiados para una imagen dada.

Aunque la complejidad del algoritmo planteado es relativamente alta, esto está relacionado con la complejidad que presenta cada uno de los métodos de clasificación disponibles en el paquete de tratamiento de imágenes con el que se está trabajando, y evidentemente de la dimensión de la imagen.

Como última conclusión, y según los resultados obtenidos, pensamos que podría ser interesante incorporar un método similar al que planteamos en este trabajo dentro de los paquetes de tratamiento de imágenes comerciales actuales. Este método podría ahorrar tiempo y esfuerzo al analista, encargado de realizar la clasificación. Además, este método asegura que el clasificador seleccionado y los parámetros escogidos son los que generarán los mejores resultados para el analista.

Como trabajo futuro, estamos experimentando con nuevos factores para la evaluación del rendimiento, de forma que lo que se pretende es analizar con todo detalle cada uno de los clasificadores. También queremos extender la metodología a métodos de clasificación basados en conjuntos difusos.

BIBLIOGRAFÍA

- AZZALI S., MENENTI M. Fourier Analysis of temporal NDVI in the Southern African and American continents, Report 108, DLO Winand Staring Center, Wageningen (The Netherlands), 1996.
- CASTLEMAN K. Digital Image Processing. Prentice Hall, 1996.
- CHUVIECO E. Fundamentos de teledetección Espacial. Editorial Rialp, 1990.
- DUDA R. O., HART P. E. Pattern Classification and scene analysis. John Wiley & Sons, 1973.
- D'URSO G., MENENTI M., Performance indicators for the statistical evaluation of digital image classifications, ISPRS Journal of Photogrammetry & Remote Sensing 51 78-90, 1996.
- JÄHNE B. Image Processing for scientific applications. CRC Press, 1997.
- SWAIN, P. H., KING, R. C. Two effective feature selection criteria for multispectral remote sensing. Proc. 1st Int. Joint Conf. Pattern Recognition. IEEE Cat.no.73 CHO 82, 1-9c, Piscataway, N.J., p.p 536-540, 1973.