

Clasificación no supervisada de nubes en imágenes NOAA-AVHRR. Técnicas de agrupamiento difuso.

Albano González, Juan C. Pérez y Abidán Cerdeña

Dpto. de Física Fundamental y Exp., Electrónica y Sistemas. Universidad de La Laguna. Avda. Francisco Sánchez s/n, 38200 La Laguna, Tenerife, Islas Canarias. aglezf@ull.es, jcperez@ull.es, acerdana@ull.es.

Resumen

En el presente trabajo se analizan las posibilidades que ofrecen las técnicas de agrupamiento difuso (*fuzzy clustering*) para la clasificación automática no supervisada de imágenes de satélite. Concretamente, estas técnicas son aplicadas, como caso de estudio, a la clasificación de nubes en imágenes nocturnas del sensor NOAA-AVHRR. Diferentes aproximaciones, tanto de técnicas de agrupamiento como de índices de validez de los grupos obtenidos, son empleados. Los mejores resultados son obtenidos utilizando aprendizaje competitivo sensible a la frecuencia, combinado con el índice propuesto por Sun et al. [1] para la búsqueda del número óptimo de grupos en un espacio de características concreto.

1. Introducción

La información espacial y temporal de la distribución de los distintos tipos de nubes, así como sus propiedades macro y microfísicas es de vital importancia en la realización de múltiples estudios ecológicos y climáticos [2]. Actualmente la forma más conveniente de obtener dicha información a escalas regionales o globales es mediante el análisis de las imágenes proporcionadas por los distintos sensores a bordo de satélites. Por ello, desde hace algunas décadas han surgido numerosos trabajos dedicados a la clasificación automática de nubes a partir de imágenes multiespectrales. Esta clasificación proporciona, además, la información necesaria para la posterior aplicación de diferentes algoritmos de extracción de los parámetros que caracterizan las distintas cubiertas nubosas [3].

Los métodos de clasificación más empleados son los basados en umbrales aplicados a las distintas bandas espectrales, o combinaciones de ellas, y los basados en entrenamiento supervisado [2]. En el primer caso, los problemas pueden surgir al usar los umbrales seleccionados en diferentes condiciones a las supuestas para su generación, por ejemplo, distinta localización geográfica o distintas geometrías de iluminación u observación. En el segundo, el sistema de-

ber ser entrenado utilizando un gran número de muestras de las diferentes clases que se deseen obtener en el proceso de clasificación. Además, las propiedades de estas muestras también variarán con las diferentes condiciones, con lo que el número de píxeles necesarios para el entrenamiento aumenta considerablemente.

Como alternativa a la clasificación basada en umbrales o a la supervisada, se pueden emplear técnicas de clasificación no supervisada. Uno de los métodos más utilizados con este fin es el agrupamiento automático de clases (*clustering*). Sin embargo, estas técnicas también presentan varios problemas, por ejemplo, el tratamiento del solape de las diferentes clases en el espacio de características o la elección del número de grupos o clases que deben obtenerse. Por esas razones, en este trabajo se estudia la aplicación de métodos de agrupamiento difuso junto al uso de índices de validez que permitan la estimación del número de grupos óptimo para una imagen determinada. Estos métodos son aplicados a imágenes nocturnas del sensor NOAA-AVHRR.

2. Agrupamiento difuso

En esta sección se presentarán brevemente los dos métodos de agrupamiento empleados. El primero basado en el extendido método de las *c*-medias (FCM - *fuzzy c-means*). El segundo, aprendizaje competitivo (CL - *competitive learning*), presenta algunas mejoras respecto FCM, sobre todo en velocidad de convergencia.

2.1. Algoritmo FCM

Ese método fue propuesto por primera vez por Bezdek [4], y clasifica una colección de vectores de características, X , de dimensión s , en c grupos homogéneos representados como conjuntos difusos ($F_i, i = 1, \dots, c$). El objetivo del algoritmo FCM es encontrar la partición difusa $F = \{F_1, \dots, F_c\}$ para el conjunto de datos $X = \{x_1, \dots, x_n\}$ que minimice la función:

$$J_m(U, V : X) = \sum_{i=1}^c \sum_{j=1}^n (\mu_{ij})^m \|x_j - v_i\|^2 \quad (1)$$

donde μ_{ij} es el grado de pertenencia del dato x_j al grupo difuso F_i , y es uno de los elementos de la matriz $U = [\mu_{ij}]$ de dimensión cn . $V = (v_1, \dots, v_c)$ representa el conjunto de los centroides de cada uno de los grupos formados. El parámetro m controla el grado de borrosidad de la pertenencia de cada uno de los datos.

Los pasos a seguir en FCM son los siguientes:

1. Inicializar U , con $\sum_{i=1}^c \mu_{ij} = 1$, y generar aleatoriamente la posición de los c centroides.

2. Calcular los centroides:

$$v_i = \frac{\sum_{j=1}^n (\mu_{ij})^m x_j}{\sum_{j=1}^n (\mu_{ij})^m} \quad (2)$$

3. Actualizar la matriz U :

$$\mu_{ij} = \left[\sum_{k=1}^c \left(\frac{\|x_j - v_i\|^2}{\|x_j - v_k\|^2} \right)^{1/(m-1)} \right]^{-1} \quad (3)$$

4. Parar si la mejora en J_m es menor que un cierto umbral (ϵ), si no, volver al paso 2.

2.2. Aprendizaje competitivo

En el algoritmo de la sección anterior la posición de los centroides se actualiza en cada iteración, teniendo en cuenta todos los datos x_j . Sin embargo, puede utilizarse una forma secuencial para realizar el agrupamiento si, para cada dato x_j presentado, la posición de los c centroides es actualizada de la siguiente forma [5]:

$$v_i(t+1) = v_i(t) + \alpha(t) (\mu_{ij})^m (x_j - v_i(t)) \quad (4)$$

donde t aumenta con cada dato presentado y $\alpha(t)$ es un parámetro de aprendizaje decreciente con t . Además, al tratarse de un aprendizaje competitivo difuso (FCL - *fuzzy competitive learning*), se ha introducido el grado de pertenencia del dato x_j al grupo cuyo centroides es v_i .

Para evitar las inestabilidades que pueden aparecer durante las primeras iteraciones al favorecerse los grupos grandes frente a los demás, las distancia entre los datos x_j y cada centroide v_j es multiplicada por:

$$n_i(t+1) = n_i(t) + (\mu_{ij})^m \quad (5)$$

Se trata de una medida difusa del número de veces que el centroide de cada clase ha sido modificado. De esta forma se obtiene un método de aprendizaje sensible a la frecuencia (FFSCL - *fuzzy frequency-sensitive competitive learning*).

3. Índices de validez de agrupamiento

Los algoritmos descritos en la sección anterior requieren el conocimiento previo del número de clases o grupos que se esperan obtener, c , lo que no siempre es posible. En el ejemplo que nos ocupa, la clasificación de nubes, puede que no existan todos los tipos de nubes posibles en una imagen o que varias de ellas se encuentren superpuestas. Por ello, es necesario utilizar una metodología de evaluación para decidir si una partición determinada, con un número de grupos c , es la óptima. Esto se consigue ejecutando los algoritmos de agrupamiento con diferente número de clases y evaluando un índice de validez diseñado a tal efecto.

Se expondrán los índices utilizados en este trabajo, que han sido elegidos por su amplia utilización o por su novedoso tratamiento de la medida del agrupamiento de las clases.

3.1. Índice de Xie-Beni

Xie y Beni propusieron el siguiente índice [6]:

$$V_{XB} = \frac{\sum_{i=1}^c \sum_{j=1}^n (\mu_{ij})^m \|x_j - v_i\|^2}{n \left(\min_{i \neq j} \|x_j - v_i\|^2 \right)} \quad (6)$$

En esta ecuación el numerador mide la densidad de los grupos, esto es, si son más o menos compactos y el denominador indica el grado de separación entre los distintos grupos. Por lo tanto, una buena partición minimizará este índice.

3.2. Índice de Kim-Lee-Lee

Kim et al. [7] proponen el índice:

$$V_{KLL} = \frac{Ov^N(c)}{Sep^N(c)} \quad (7)$$

con,

$$Ov^N(c) = \frac{Ov(c)}{\underbrace{\max}_c Ov(c)}, \quad Sep^N(c) = \frac{Sep(c)}{\underbrace{\max}_c Sep(c)} \quad (8)$$

y

$$Ov(c) = \frac{2}{c(c-1)} \sum_{p=1}^{c-1} \sum_{q=p+1}^c \sum_{\mu} \sum_{j=1}^n \delta(x_j, \mu, F_p, F_q) \quad (9)$$

$$Sep(c) = 1 - \min_{p \neq q} \left[\max_{x \in X} \min(\mu_{F_p}(x), \mu_{F_q}(x)) \right] \quad (10)$$

donde $\delta(x_j, \mu, F_p, F_q)$ determina el grado de superposición de los agrupamientos si $\mu_{F_p}(x)$ y

$\mu_{F_q}(x)$ son mayores que μ y es nula en caso contrario. El numerador de la ecuación 7 está relacionado con el grado de solapamiento promedio para todos los grupos de la partición. El denominador mide la mínima separación entre todos los pares de píxeles. Por lo tanto, el objetivo es minimizar V_{KLL} .

3.3. Índice de Tsekouras-Sarimveis

Estos autores definen el índice de validez [8]:

$$V_{TS} = \frac{\sum_{i=1}^c \frac{\sum_{j=1}^n (\mu_{ij})^m \|x_j - v_i\|^2}{\sum_{j=1}^n \mu_{ij}}}{\sum_{i=1}^{c+1} \sum_{k=1, i \neq k}^{c+1} (\mu_{ik})^{(2+w)/w} \|z_k - z_i\|^2} \quad (11)$$

donde $[z_1, \dots, z_c, z_{c+1}]^T = [v_1, \dots, v_c, \bar{x}]^T$ y $\bar{x} = \sum_{j=1}^n x_j/n$. w define la borrosidad de la separación difusa entre las clases, propiedad que mide el denominador de la ecuación. El numerador depende de si los grupos son poco o muy compactos. De nuevo, se busca una minimización de este índice.

3.4. Índice de Sun-Wang-Jiang

En este caso el índice de validez es [1]:

$$V_{SWJ} = Scat(c) + Sep(c)/Sep(c_{max}) \quad (12)$$

$$\text{con } Scat(c) = \frac{\frac{1}{c} \sum_{i=1}^c \|\sigma(v_i)\|}{\|\sigma(X)\|} \quad (13)$$

donde $\sigma(X) = \{\sigma(X)^1, \dots, \sigma(X)^s\}$, $\sigma(X)^p = \frac{1}{n} \sum_{j=1}^n (x_j^p - \bar{x}^p)^2$, $\sigma(v_i) = \{\sigma(v_i)^1, \dots, \sigma(v_i)^s\}$ y $\sigma(v_i)^p = \frac{1}{n} \sum_{j=1}^n \mu_{ij} (x_j^p - v_i^p)^2$. $Scat(c)$ depende de si los grupos son bastante o poco compactos. El término que representa la separación entre los grupos es:

$$Sep(c) = \frac{D_{max}^2}{D_{min}^2} \sum_{i=1}^c \left(\sum_{k=1}^c \|v_i - v_k\|^2 \right)^{-1} \quad (14)$$

donde $D_{min} = \min_{i \neq k} \|v_i - v_k\|$ y $D_{max} = \max_{i, k} \|v_i - v_k\|$. Por lo tanto el número de grupos óptimo será aquel que minimice la ecuación 12.

4. Aplicación a la clasificación de nubes

4.1. Datos y características utilizadas

En este trabajo se han utilizado imágenes nocturnas del sensor NOAA-AVHRR para probar la efectividad de los métodos de agrupamiento y cálculo del número óptimo de clases. Esto es debido a la dificultad que presentan las imágenes nocturnas para separar algunos tipos de nubes de la superficie y distintos tipos de nubes entre sí, al no disponer de la información de la radiación solar reflejada por las nubes. Además,

la mayor parte de métodos de clasificación de nubes han sido desarrollados para imágenes diurnas.

Se han realizado pruebas utilizando diferentes conjuntos de características sencillas. Finalmente, se han escogido dos conjuntos. Por un lado, se utilizó un espacio de 3 características, compuestas por las temperaturas de brillo de los canales 3, 4 y 5 del AVHRR (T_3, T_4 y T_5). Por otro, se emplearon seis características sugeridas por varios autores (ej. [2]): Las temperaturas de los canales 4 y 5 (T_4 y T_5), las diferencias $T_4 - T_3, T_3 - T_5$ y $T_4 - T_5$, y la varianza en subimágenes 3x3 de T_4 (σ_{T_4}).

4.2. Resultados

Los métodos expuestos en las secciones anteriores fueron aplicados a múltiples imágenes nocturnas del NOAA-14. El algoritmo FCM necesita múltiples iteraciones para converger, unas veinte veces más que al utilizar FFSCl, por lo que el tiempo requerido es mucho mayor. Por lo tanto se utilizó esta última técnica para comprobar la efectividad de los índices de validez.

En la figura 1 se muestran los índices de validez obtenidos para tres imágenes de ejemplo y los dos conjuntos de características elegidos, de 3 y 6 dimensiones respectivamente. Puede observarse que sólo el índice V_{Wsj} es capaz de calcular el número de grupos óptimo. V_{XB} , a pesar de presentar varios mínimos locales, siempre ofrece como valor óptimo 2. Los otros dos decrecen al aumentar el número de grupos. Además, los resultados son muy similares al utilizar los dos conjuntos de características.

En la figura 2 se muestra un ejemplo de clasificación automática de una imagen AVHRR. En la parte superior aparece la imagen del canal 4 y en la inferior las 5 clases en las que se ha dividido automáticamente la imagen.

5. Conclusiones

En este trabajo se ha mostrado la potencia del método de agrupamiento difuso FFSCl junto al índice de validez V_{Wsj} para la clasificación automática no supervisada de nubes a partir de imágenes nocturnas AVHRR. Sin embargo, es necesario evaluar el método propuesto de forma cuantitativa con múltiples imágenes y utilizar más características, como aquellas basadas en medidas de textura.

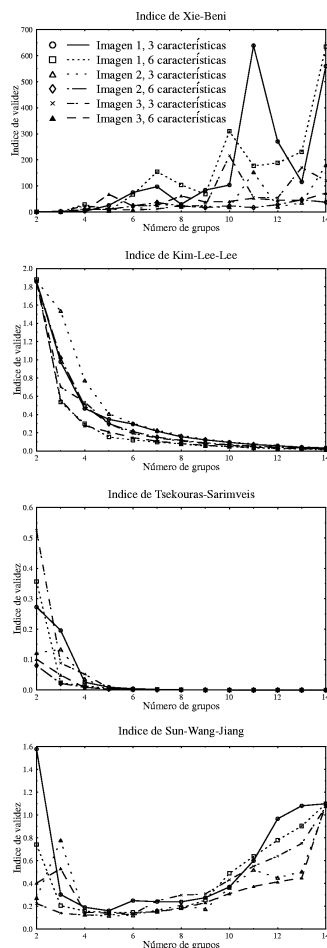


Figura 1: Comportamiento de los índices de validez.

6. Agradecimientos

Este trabajo ha sido financiado gracias al Ministerio de Ciencia y Tecnología de España (P.I. REN2003-08013) y a los fondos FEDER.

7. Referencias

[1] Sun, H., S. Wang, and Q. Jiang, "FCM-based model selection algorithms for determining the number of clusters", *Pattern Recognition*, 37, 2027-2037, 2004.

[2] Bendix, J., R. Rollenbeck y W.E. Palacios, "Cloud detection in the Tropics - a suitanle




Figura 2: Ejemplo de clasificación automática de la imagen superior (T_A).

tool for climatic-ecological studies in the high mountains of Ecuador", *Int. J. Rem. Sensing*, 21, 4521-4540, 2004.

[3] Wang, Z., y K. Sassen, "An improved cloud classification algorithm based on the SGP CART site observations", *14th ARM Science Team Meeting Proc.*, 2004.

[4] Bezdek, J.C., *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.

[5] Kohonen, T., *Self-organizing maps*, Springer, 1995.

[6] Xie, X.L., y G. Beni, "A validity measure for fuzzy clustering", *IEEE Trans. Pattern Anal. Mach. Intell.*, 13, 841-847, 1991.

[7] Kim, D.W., K.H. Lee, y D. Lee, "On cluster validity index for estimation of the optimal number of fuzzy clusters", *Pattern Recognition*, 37, 2009-2025, 2004.

[8] Tsekouras, G.E., y H. Sarimveis, "A new approach for measuring the validity of the fuzzy c-means algorithm", *Advances in Engineering Software*, 35, 567-575, 2004.