

CLASIFICACIÓN TEMÁTICA DE IMÁGENES REMOTAMENTE DETECTADAS MEDIANTE REDES NEURONALES AUTOORGANIZATIVAS CON ESTRUCTURAS CELULARES QUE CRECEN.

Soledad Delgado (*), Consuelo Gonzalo (**), Estíbaliz Martínez (**), y Águeda Arquero (**)

sole@eui.upm.es

(* *Departamento de Informática Aplicada. Escuela Universitaria de Informática (UPM). Camino de la Arboleda, s/n (Complejo Politécnico de Vallecas) Carretera de Valencia Km. 7, Madrid – 28031*

(**) *Departamento de Arquitectura y Tecnología de Sistemas Informáticos, Facultad de Informática (UPM). Campus de Montegancedo, (Boadilla del Monte) Madrid - 28660*

RESUMEN

En este trabajo se analizan las redes neuronales autoorganizativas con estructuras celulares que crecen, basadas en el trabajo de Fritzke, y se evalúa su rendimiento en la clasificación temática de imágenes del LANDSAT 7 TM. Se han considerado dos criterios de inserción de neuronas para la fase de entrenamiento: la estimación de la función densidad de probabilidad de las señales de entrada y la equiparación de una medida de error acumulado. Para evaluar la calidad del aprendizaje de las redes neuronales entrenadas se ha utilizado un conjunto representativo de píxeles etiquetados por un experto.

Self-Organizing Neural Networks (SONN) with growing capability, based in Fritzke work, has been investigated and their performances evaluated for thematic classification of Landsat 7 TM images. During the training phase, two different growing criteria have been considered and studied: the estimation of the unknown probability density of the input signals and the equalization of an accumulated error measure. The goodness of the neural network learning has been evaluated using a representative set of pixels labeled by an expert.

Palabras clave: clasificación, estructuras celulares que crecen, imágenes multiespectrales, redes neuronales autoorganizativas, aprendizaje no supervisado.

INTRODUCCIÓN

La clasificación de imágenes multiespectrales capturadas por satélite es un problema característico del agrupamiento de datos multidimensionales. Cuando se utilizan métodos estadísticos clásicos para abordar esta tarea, es necesario disponer de modelos probabilísticos, que suelen ser difíciles de obtener. En estos casos, las redes neuronales (RN) son una buena alternativa (Atkinson y Tate 1999). Habitualmente se han utilizado RN de tipo Back Propagation (aprendizaje supervisado) para la clasificación de imágenes multiespectrales capturadas por satélite (Bischof *et alii.* 1992) (Heermann y Khazenie 1992) (Miller *et alii.* 1995). Más recientemente se han aplicado RN de tipo ART a este mismo problema (Al-Rawi *et alii.* 1999). En este trabajo se expone el uso de RN Auto-Organizativas (RNAO) con estructuras celulares que crecen para la clasificación de imágenes multiespectrales capturadas por el sensor Landsat 7 ETM+.

En el primer modelo de RNAO (Kohonen 1982) la fase de entrenamiento tenía como objetivo

la búsqueda de las relaciones espaciales que existían entre los patrones de entrada, de forma que, las neuronas que se encontrasen físicamente próximas se activasen frente a patrones de entrada similares. Las RNAO utilizan aprendizaje no supervisado, por lo que no es necesario conocer a priori la salida que debe generar la red para cada dato de entrada usado en el entrenamiento. La mayor desventaja que presenta el modelo de RN de Kohonen es la necesidad de especificar la estructura completa de la red antes de iniciar el proceso de entrenamiento. Diversos autores (Fritzke 1994) (Blackmore y Miikkulainen 1992) (Burzevski y Mohan 1996) han propuesto RNAO que abordan este problema. Todos ellos comienzan la fase de aprendizaje con un número mínimo de neuronas y aplican heurísticos para determinar cuándo y dónde se debe insertar una nueva neurona y cómo conectarla con el resto. Además, plantean la posibilidad de eliminar aquellas neuronas y conexiones que no se consideren representativas. La diferencia básica entre estas soluciones radica en los modelos de conexión entre neuronas y en la naturaleza de los algoritmos heurísticos. En el modelo propuesto por Fritzke

(Fritzke 1994) se utiliza una topología de hipertetraedro k -dimensional para la conexión entre neuronas y diversos heurísticos para determinar dónde insertar nuevas neuronas y cuáles eliminar. En este trabajo se utiliza este modelo aplicado al problema real de la clasificación de imágenes remotamente detectadas.

REDES NEURONALES AUTOORGANIZATIVAS (RNAO) DE FRITZKE

El modelo de RNAO propuesto por Fritzke presenta una topología de dos capas de neuronas: de entrada y de salida. Las neuronas de entrada se encuentran totalmente conectadas a las de salida mediante conexiones de tipo feedforward que tienen asociado un peso, w_{ij} , donde i identifica a la neurona de entrada y j a la de salida. En este modelo, las neuronas de salida presentan conexiones de vecindad entre ellas, que no tienen asociado ningún peso. Esta vecindad está formada por conjuntos de estructuras de hipertetraedros k -dimensionales básicos, donde las neuronas se sitúan en los vértices y las aristas representan conexiones de vecindad. Para $k=1$, la estructura básica es un segmento que une dos neuronas, para $k=2$, es un triángulo que une tres neuronas y para $k=3$ o más, es un hipertetraedro que une $k+1$ neuronas. La Figura 1 muestra una RNAO de Fritzke con $k=2$, N neuronas de entrada y 4 neuronas de salida.

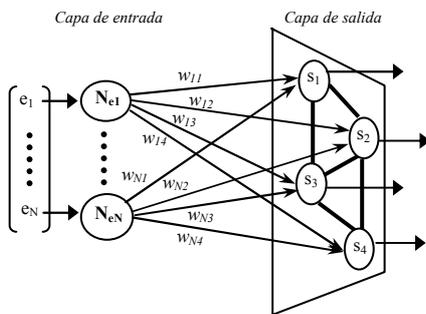


Figura 1.-Red neuronal de Fritzke con $k=2$.

Cuando se presenta un patrón de entrada (vector $[e_1, \dots, e_N]$) a la red, cada neurona de entrada transmite a todas sus conexiones de salida el valor de entrada que recibe (e_i). Por otro lado, cada neurona de salida recibe los pesos asociados a sus conexiones de entrada (vector sináptico) y los valores transmitidos a través de ellas. Al procesar un patrón de entrada por la red sólo se activará una neurona de salida (ganadora), que será aquella cuya distancia Euclídea entre su vector sináptico y el vector de entrada sea la menor de todas. Formalmente, la función de activación de una

neurona de salida es la expresada en la ecuación 1.

$$S_j = \begin{cases} 1, \text{MIN} \left(\sqrt{\sum_{i=1}^N (e_i - w_{ij})^2} \right) & \forall j \in \text{capa de salida} \\ 0, \text{en caso contrario} \end{cases} \quad (1)$$

Las RN de Fritzke se encuentran dentro de las denominadas RNAO con estructuras celulares que crecen, ya que durante la fase de aprendizaje se incorporan nuevas neuronas a la capa de salida y se eliminan aquellas que se consideran superfluas (Fritzke 1994). El objetivo que se persigue con el aprendizaje es modificar los vectores sinápticos de las neuronas de salida hasta que cada una represente a un conjunto de patrones de entrada similares. En cada iteración del entrenamiento se determina qué neurona es la ganadora, S , y se modifica su vector sináptico de acuerdo a la ecuación:

$$w_{iS}(t+1) = w_{iS}(t) + \varepsilon_b [e_i - w_{iS}(t)] \quad i = 1, \dots, N \quad (2)$$

donde la constante ε_b es un parámetro de adaptación de pesos. Los vectores sinápticos de las neuronas vecinas de la ganadora sufren la misma modificación (ecuación 2), excepto que el parámetro de adaptación de pesos utilizado en este caso es ε_n . Habitualmente, el valor de ε_b es mayor que el de ε_n (Fritzke 1994). Fritzke propone dos heurísticos de inserción de neuronas: "Estimación de la Función de Densidad de Probabilidad" (EFD) y "Equiparación de una medida de Error Acumulado" (EEA). Además, cuando los patrones de entrenamiento presentan una distribución de varias regiones separadas con densidad de probabilidad positiva, Fritzke plantea eliminar las neuronas de salida que tienen un vector sináptico ubicado en una región con baja densidad de probabilidad. En general, la densidad de probabilidad de los patrones de entrenamiento se desconoce, por lo que se utiliza una estimación local. Periódicamente se eliminan las neuronas de la capa de salida situadas en una región con densidad de probabilidad estimada menor que un umbral constante, η .

EXPERIMENTOS

Partiendo de una imagen de 121500 píxeles de la zona Oeste de Madrid, registrada por el sensor ETM+ (LANDSAT 7), el 20 de agosto de 1999, se ha seleccionado un conjunto representativo de 1922 píxeles, correspondientes a las clases temáticas etiquetadas como: matorral, bosque caduco, pinar, suelo, agua y mixto. De ellos, un 78% se han usado para entrenar y etiquetar las RN y el resto para la fase de testeo. A continuación, se han entrenado varias redes usando los dos criterios de inserción de neuronas planteados por Fritzke: EFD y EEA. En ambos casos, el único factor que se ha variado es el número máximo de neuronas de la capa de salida de

la red (desde 6 hasta 75), siendo ésta la condición de finalización del entrenamiento. Los parámetros fijos usados en los experimentos son: $N = 6$, $k = 2$, $\epsilon_s = 0.06$, $\epsilon_n = 0.002$, $\eta = 0.09$. El número de neuronas de entrada (N) viene establecido por las seis bandas espectrales de la misma resolución espacial del sensor ETM+, de forma que cada uno de los elementos, e_i , de un vector representa el nivel de gris (entre 0 y 255) de la banda espectral correspondiente. Con el criterio EFDP se consigue clasificar correctamente el 99.9% de los patrones de entrenamiento cuando la capa de salida dispone de al menos 30 neuronas. Con el criterio EEA se precisan al menos 40 neuronas para alcanzar este porcentaje. Una estrategia conservadora aconseja utilizar una red de 40 neuronas con EFDP y otra de 50 con EEA.

Las RNAO se caracterizan por su aprendizaje no supervisado, esto es, en la fase de entrenamiento sólo se presentan a la red los patrones de entrada sin ningún tipo de información respecto a la clase temática a la que pertenecen. De esta forma, las neuronas de la capa de salida se distribuyen en las áreas en las que se encuentran situados los patrones de entrenamiento (en un espacio espectral de 6 dimensiones). Posteriormente a la fase de aprendizaje es preciso etiquetar la red. Ésta se ha llevado a cabo presentando a la red pares patrón-clase, de forma que cada neurona se etiqueta con la clase asociada al patrón de entrada más cercano a su vector sináptico.

RESULTADOS

La calidad de clasificación se ha evaluado mediante las correspondientes matrices de confusión. La Tabla 1 muestra la matriz de confusión obtenida con la RN de 40 neuronas entrenada con EFDP y la Tabla 2 la obtenida con la RN de 50 neuronas entrenada con EEA. Los resultados ofrecen un 97.8% de precisión para la primera RN y un 96% para la segunda.

Cuando la densidad de probabilidad de los patrones de entrenamiento presenta una distribución no uniforme, los dos criterios de inserción de neuronas generan vectores sinápticos sensiblemente diferentes (Fritzke 1994). Esto es mostrado en la Figura 2. La Tabla 3 resume el porcentaje de neuronas de salida asociadas a cada una de las seis categorías temáticas en ambas RN, así como el porcentaje de patrones de entrenamiento que pertenece a cada categoría.

RN 40						
suelo	196	1	0	0	0	0
mixto	0	39	0	0	0	0
matorral	0	1	52	0	7	0
caduco	0	0	0	37	0	0
pinar	0	0	0	0	68	0
agua	0	0	0	0	0	21

Tabla 1.-Matriz de confusión de RN de 40 neuronas.

Experto	suelo	mixto	matorral	caduco	pinar	agua
RN 50						
suelo	196	2	0	0	0	0
mixto	0	38	0	0	0	0
matorral	0	1	52	0	8	0
caduco	0	0	0	37	6	0
pinar	0	0	0	0	61	0
agua	0	0	0	0	0	21

Tabla 2.-Matriz de confusión de RN de 50 neuronas.

Clases	RN con 40 neuronas	RN con 50 neuronas	% patrones de entrenamiento
suelo	40%	42%	46.7%
mixto	7.5%	14%	9.3%
matorral	17.5%	14%	12.3%
caduco	10%	14%	8.5%
pinar	17.5%	14%	18%
agua	7.5%	2%	5.2%

Tabla 3.- Distribución de neuronas y patrones de entrenamiento (%) por clase.

CONCLUSIONES

Las RNAO con estructuras celulares que crecen ofrecen buenos resultados de representación y clasificación de datos remotamente detectados. La ventaja principal de este tipo de RN frente a las utilizadas habitualmente para realizar esta tarea radica en la simplicidad de su arquitectura, sin capas de neuronas ocultas, y en un proceso sencillo de adaptación de los pesos de la red durante el entrenamiento. El modelo de RNAO de Fritzke ofrece como ventaja frente al de Kohonen, la formación dinámica y automática de la topología de la capa de salida de la red durante el entrenamiento. Aunque en los experimentos realizados ha sido necesario indicar el número máximo de neuronas de la capa de salida, actualmente se está estudiando la viabilidad de determinar este factor automáticamente.

La representación de los vectores sinápticos muestra la distribución de los patrones de entrenamiento en el dominio espectral, ofreciendo una evaluación automática de la calidad de la selección de los propios patrones de entrenamiento. Esta característica es una contribución importante en el campo de la detección remota.

La distribución no homogénea de los

Experto	suelo	mixto	matorral	caduco	pinar	agua
---------	-------	-------	----------	--------	-------	------

patrones de entrenamiento utilizados en los experimentos ha ofrecido resultados distintos para los dos criterios de inserción de neuronas considerados. Así, se ha mostrado que el criterio EFDP necesita menor número de neuronas que EEA y, además ofrece mayor precisión en los resultados.

Aunque los datos obtenidos hasta el momento son muy prometedores, será necesario entrenar nuevas RNAO de Fritzke variando los valores de algunos parámetros, como el umbral de eliminación de neuronas (η) o la dimensión del tetraedro (k).

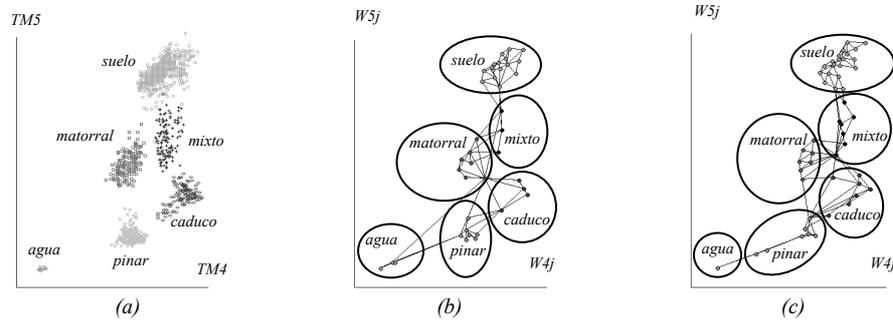


Figura 2.- (a) Escatergrama de los patrones de entrenamiento para las bandas espectrales TM4 y TM5 (cada nube de puntos está etiquetada con la clase temática a la que pertenece). Distribución espacial de las neuronas de salida en el espacio de los pesos de entrada W_{4j} y W_{5j} , (b) para la RN de 40 neuronas entrenada con el criterio EFDP y (c) para la RN de 50 neuronas entrenada con el criterio EEA.

BIBLIOGRAFÍA

Al-Rawi, K.R., Gonzalo, C. and Arquero, A. 1999. Supervised ART-II: a new neural network architecture, with quicker learning algorithm, for classifying multivalued input patterns. *Proc. of the ESANN*, Bruges, Belgium : 289-294.

Atkinson, P.M. and Tate, N.J. 1999. *Advance in Remote Sensing and GIS Analysis*. J. Wiley & Sons.

Bischof, H., Schneider, W. and Pinz, A.J. 1992. Multispectral classification of Landsat-images using neural networks. *IEEE Trans. Geoscience and Remote Sensing* 30, no.3: 482-490.

Blackmore, J. and Miikkulainen, K. 1992. Incremental grid growing: encoding high-dimensional structure into a two-dimensional feature map. *Department of Computer Science, University of Texas, Austin, TX, Tech. Rep. AI92-192*.

Burzevski, V. and Mohan, C.K. 1996. Hierarchical growing cell structures. *IEEE International Conference on Neural networks, New York, NY* 3: 1658-1663.

Fritzke, B. 1994. Growing cell structures – a self-organizing network for unsupervised and supervised learning. *Neural Networks*, 7, no.1: 1441-1460.

Heermann, P. and Khazenie, N. 1992. Classification of multispectral remote sensing data using a back-propagation neural network. *IEEE Trans. Geoscience and Remote Sensing* 30, no.1: 81-88.

Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43: 59-69.

Miller, D.M., Kaminsky, E.J. and Rana, S. 1995. Neural networks classification of remote-sensing data. *Computers & Geosciences* 21, no.3: 377-386.

AGRADECIMIENTOS

Este trabajo ha sido financiado por la Comisión Interministerial de Ciencia Y Tecnología (CICYT), nº TIC 99-0930.