

USO DE REDES NEURONALES AUTOORGANIZATIVAS DINÁMICAS NO SUPERVISADAS PARA LA DISCRIMINACIÓN DE TIPOS DE AGUAS EN LAGOS

Delgado Soledad¹; Gonzalo Consuelo²; Lillo-Saavedra Mario³, Martínez Estibaliz²; Arquero Agueda²

¹ *Departamento de Organización y Estructura de la Información, Escuela Universitaria de Informática, Universidad Politécnica de Madrid. Ctra. De Valencia, Km. 7, 28031, Madrid, España. sole@eui.upm.es*

² *Departamento de Arquitectura y Tecnología de Sistemas Informáticos, Facultad de Informática, Universidad Politécnica de Madrid. Campus de Montegancedo, 28660, Boadilla del Monte, Madrid, España. {chelo, emartinez, arquero}@fi.upm.es*

³ *Departamento de Mecanización y Energía, Facultad de Ingeniería Agrícola, Universidad de Concepción, Avda. Vicente Méndez 595, Casilla 537, Chillán, Chile. malillo@udec.cl*

Palabras clave: redes neuronales autoorganizativas, clasificación, no supervisado, tipología de agua.

INTRODUCCIÓN

Las técnicas de clasificación supervisadas aplicadas a imágenes de satélite requieren la selección de muestras representativas de los distintos tipos de clases de cubiertas presentes en la imagen a analizar. El proceso de selección de áreas y su categorización son trabajos que habitualmente se realizan de manera manual por un experto o bien mediante campañas de campo. Para el caso particular de clasificación de imágenes con cubiertas acuosas con diferentes características, hay tres aspectos muy importantes a considerar; en primer lugar, la baja separabilidad de las respuestas espectrales de cada una de las clases de aguas; en segundo lugar, el hecho de que para mejorar los resultados sea necesario trabajar con imágenes de alta resolución, lo que implica que para lagos de tamaños medios y grande el volumen de datos es muy elevado y consecuentemente se requieren una gran cantidad de muestras de entrenamiento; finalmente, cabe destacar el alto costo y complejidad de las tomas de datos en terreno. En este sentido, para los cuerpos de agua parece más aconsejable la utilización de técnicas de clasificación no supervisadas que reducen al máximo la necesidad de una supervisión del proceso por parte de un experto.

Los mapas autoorganizativos son un modelo de red neuronal que se engloban dentro de los métodos de clasificación no supervisados. Su origen data de 1982, cuando Kohonen [1] planteó una arquitectura de red neuronal y un proceso de entrenamiento que perseguía dos objetivos claros: conseguir un modelo simplificado de los datos de entrada así como obtener un mapa bidimensional que permitiese mostrar gráficamente las relaciones existentes entre estos. Estas propiedades han permitido desarrollar distintos métodos de visualización de información multidimensional [2-5] que se han aplicado a una gran variedad de disciplinas, entre las que se encuentra la teledetección. A pesar de las buenas características que exhibe el modelo de Kohonen, cabe destacar como inconveniente la necesidad de determinar la arquitectura exacta de la red antes de someterla al entrenamiento, así como la imposibilidad de modificar su diseño durante el mismo. Esto provoca que ante determinadas distribuciones de patrones de entrada, la red entrenada pueda llegar a ofrecer bajas medidas de lo que se conoce como preservación de la topología [6], valor que permite evaluar la bondad del modelo simplificado que representa la red. En la década de los años 90 se presentaron nuevos

modelos de mapas autoorganizativos que pretendían solucionar este problema [7-9]. Entre ellos, cabe destacar el modelo conocido como Growing Cell Structures (GCS), planteado por B. Fritzke en 1994. La red GCS ofrece como principal ventaja frente al modelo de Kohonen la dinamicidad de la arquitectura de la capa de salida de la red durante la fase de entrenamiento de la misma. Esta característica permite obtener modelos simplificados de los datos con mejores medidas de la preservación de la topología. Además, las redes GCS mantienen la propiedad de sus predecesoras de ofrecer un mapa bidimensional que permite visualizar las relaciones existentes entre los patrones de entrada, por lo que pueden utilizarse como modelo base de distintos métodos de visualización de información multidimensional [10].

En este trabajo se presenta una metodología no supervisada de clasificación basada en redes neuronales autoorganizativas dinámicas (GCS), que utiliza todos los píxeles de un lago en particular para obtener un modelo simplificado de esta información que permita determinar a qué clase pertenece cada píxel. El único dato que debe establecerse es el número de clases que se desean discriminar. El resto del proceso se produce de manera automática. En general, el método se divide en tres fases: reducir el volumen de información original, intentando minimizar la pérdida de conocimiento y eliminando redundancias presentes en los datos; analizar y obtener un conjunto de vectores representativos de cada una de las clases a discriminar; y finalmente, clasificar los píxeles de la imagen original. En las tres fases se utiliza el modelo GCS como base. El método que se propone se ha aplicado a una escena, de 7 mega píxeles, de una imagen capturada por el sensor multiespectral del satélite KOMPSAT.

EL MODELO GCS

Los mapas autoorganizativos son modelos que disponen de una arquitectura organizada en una capa de entrada, con tantas unidades como dimensiones tengan los patrones a procesar, y una de salida formada por neuronas conectadas mediante enlaces de vecindad. Todas las unidades de la capa de entrada están conectadas a todas las unidades de la capa de salida mediante enlaces que tiene asociados un peso. Las unidades de la capa de entrada son meramente propagadoras de los componentes de un patrón a todas las neuronas de la capa de salida. Cada vez que se procesa un patrón, cada unidad de la capa de salida lo recibe a través de sus conexiones de entrada y calcula la distancia Euclídea existente entre el patrón y lo que se denomina el vector sináptico de la unidad, formado por el conjunto de pesos asociado a sus conexiones de entrada. Las redes autoorganizativas siguen el principio de “el ganador se lo lleva todo” (winner takes-all), ya que al presentar un patrón a la red todas las neuronas de la capa de salida compiten por ser la ganadora (best matching unit). Sólo se activa aquella unidad de la capa de salida cuya distancia Euclídea entre su vector sináptico y el patrón procesado sea menor.

Durante el proceso de entrenamiento de los mapas autoorganizativos, se adaptan los pesos de los vectores sinápticos de las neuronas de la capa de salida buscando que las unidades vecinas se activen ante vectores de entrada similares y que los patrones similares activen siempre neuronas de salida vecinas o cercanas. Esta es la definición informal del término de preservación de la topología, que sirve para medir la precisión o bondad de adaptación del modelo simplificado al que representa la red. De manera genérica, una vez finalizado el proceso de adaptación de la red, los vectores sinápticos de las neuronas de salida podrían considerarse como prototipos de los patrones usados en el entrenamiento. Estos prototipos se consiguen de manera empírica durante el proceso de aprendizaje, en el que se presentan a la red de manera iterativa un conjunto de patrones a modelizar.

En las redes GCS, el proceso de entrenamiento comienza con una capa de salida formada por $k+1$ neuronas interconectadas entre sí por enlaces de vecindad. En este artículo, en todas las redes entrenadas se ha trabajado con el factor $k=2$, por lo que las redes

inicialmente están formadas por tres neuronas conectadas entre sí, tal y como puede observarse en la Figura 1. Durante el entrenamiento se procesan de forma iterativa los patrones, determinando cuál es la neurona ganadora y modificando su vector sináptico y el de sus vecinas inmediatas, de manera que éstos se acerquen o asemeje un poco más al patrón recién procesado. En determinados momentos de la fase de aprendizaje se producen inserciones de nuevas neuronas, de forma que la capa de salida mantenga una formación de vecindad de unidades k-dimensionales básicas, que para el factor k=2 son triángulos. De igual manera, cada cierto número de iteraciones se procede a eliminar de la capa de salida aquellas neuronas que se consideren superfluas, es decir, las que tengan un vector sináptico ubicado en una zona del espacio de entrada con una baja o nula densidad de probabilidad. Este proceso de eliminación también asegura la arquitectura de estructuras k-dimensionales básicas de la capa de salida. Normalmente, cuando los patrones de entrada presentan una distribución en regiones separadas con densidad de probabilidad positiva, la eliminación de neuronas puede provocar que la capa de salida quede formada por cluster aislados de neuronas. Esta característica, junto con la flexibilidad y dinámica de las conexiones de vecindad en el proceso de inserción de neuronas, hace que las redes GCS normalmente ofrezcan mejores grados de preservación de la topología que las redes de Kohonen. Para conseguir una mejor interpretación de los parámetros de entrenamiento de las redes GCS, en este trabajo se ha utilizado la mejora del algoritmo de entrenamiento planteada en [11].

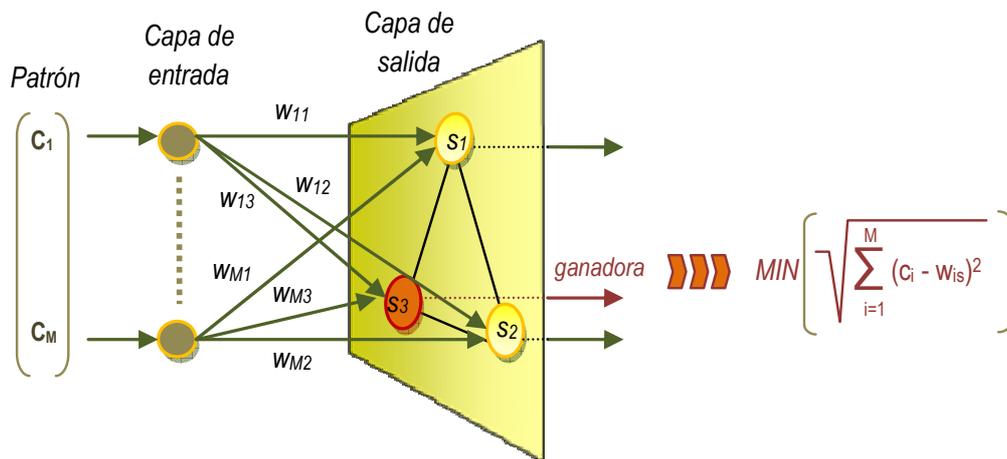


Figura 1. Arquitectura de una red GCS con tres neuronas y con factor k=2.

Con objeto de poder proyectar en el plano la capa de salida de las redes GCS, definida por las neuronas de dicha capa junto con sus conexiones de vecindad, ésta debe ser bidimensional, lo que impone un valor de k=2. Esta proyección se denomina mapa topográfico. En [10] se plantea la generación de diversos mapas topográficos, inicialmente definidos para el modelo de Kohonen, aplicados al modelo GCS. En este trabajo se han utilizado estos gráficos para analizar diversas características de las redes entrenadas.

METODOLOGÍA

La discriminación entre cubiertas acuosas con respuestas espectrales diferentes en una imagen espectral capturada por un satélite presenta el problema de la baja variabilidad existente entre las firmas espectrales asociadas a cada tipo. Una forma de mejorar este inconveniente se basa en manejar imágenes de alta resolución, que permiten una mejor discriminación pero que añaden el problema de tener que manejar un alto volumen de información. Se precisa de alguna metodología que permita por un lado reducir el volumen de información a manejar y por otro lado que consiga detectar y discriminar las diferentes clases

de agua, todo ello de manera automatizada y con la menor supervisión posible por parte de un experto. Tal y como hemos visto en el apartado anterior, las redes GCS consiguen esos dos objetivos: reducen el volumen de datos a través de los vectores sinápticos y discriminan tipos de patrones mediante el proceso de eliminación de neuronas, que separa las unidades de la capa de salida en clusters aislados que tipificarán las diferentes clases de cubiertas de agua.

La metodología que se presenta en este trabajo queda esquematizada en la Figura 2. En una primera fase se aplica una máscara a la imagen original para obtener únicamente los píxeles de agua. El volumen de información que se genera es demasiado elevado para poder entrenar una única red que permita reducirlo. Por ello, en una segunda fase se separan los píxeles de agua en N cortes de igual volumen. Cada uno de estos cortes se utiliza para entrenar una red GCS sin eliminación de neuronas (tercera fase), cuyo entrenamiento concluye cuando la red consigue 100 unidades en la capa de salida. Los 100 vectores sinápticos de cada red son los prototipos de los píxeles usados en la fase de entrenamiento. En la cuarta fase del modelo se fusionan todos ellos en un único fichero que consta de $100 \cdot N$ vectores. En este instante se ha conseguido la reducción del volumen de datos de la imagen, eliminando redundancias e intentando mantener todo el conocimiento presente en los píxeles de agua originales. La última fase del modelo persigue la búsqueda de clusters o tipologías de agua. Para ello, en primer lugar y para poder analizar gráficamente el posible número de clusters se entrena de nuevo una red GCS sin proceso de eliminación de neuronas y con finalización al conseguir 100 unidades en la capa de salida. Esta red la usaremos para generar algunas imágenes de su mapa topográfico y poder sacar alguna conclusión sobre el número de posibles tipos de aguas que podrían discriminarse en la imagen original. Teniendo en cuenta esta información se entrena una nueva red GCS con eliminación de neuronas y usando como criterio de finalización la obtención de un número mínimo de clusters de neuronas aisladas en la capa de salida. Los vectores sinápticos de las neuronas de un cluster concreto formarán un conjunto de vectores prototipo que caracterice el comportamiento espectral de un tipo de agua determinado.

La última red GCS entrenada puede etiquetarse usando un método no supervisado en el que a todas las neuronas que pertenecen al mismo cluster se les asocia la misma etiqueta que consta de un conjunto de caracteres único para ese grupo. Esta red etiquetada puede utilizarse para clasificar los píxeles de agua de la imagen original. Para ello, se determina para cada uno de los píxeles procesados por la red, qué neurona es la ganadora y se clasifica el píxel asociándole la etiqueta de esta neurona.

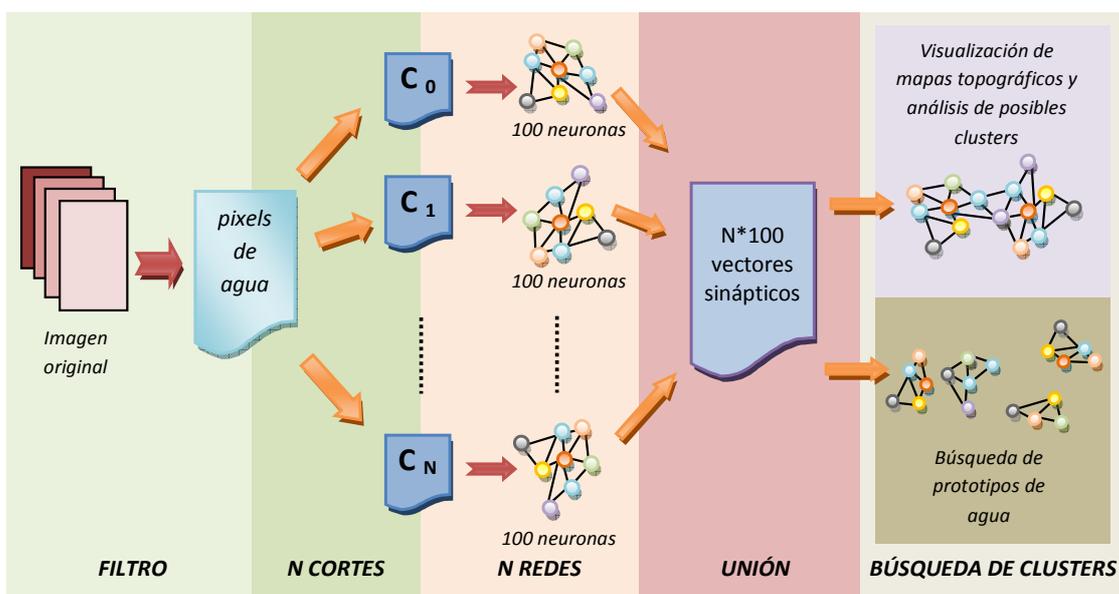


Figura 2. Fases de la metodología de clasificación no supervisada basada en redes GCS.

PRUEBAS Y RESULTADOS

Para mostrar la validez de la metodología expuesta en el apartado anterior, se ha utilizado una escena de 3451x2136 píxeles de una imagen capturada por el sensor multiespectral del satélite KOMPSAT, cuya resolución espacial es de 4m y espectral de 4 bandas (R, G, B y Nir). La imagen fue registrada el 23 de abril de 2008 y sus coordenadas geográficas, de centro de imagen, corresponden a -36,81527 LAT y -73,11308995 LONG.

Como resultado de la primera fase, que corresponde a la aplicación de la máscara, se ha creado un fichero que consta de 1256618 píxeles de agua. Se han generado 30 cortes con aproximadamente 41889 píxeles cada uno. Al finalizar los entrenamientos de las 30 redes GCS, correspondientes a los 30 cortes, se han fusionado en un único fichero los 3000 vectores sinápticos de las mismas.

En la fase de búsqueda de clusters, en primer lugar se ha entrenado una red GCS sin eliminación de neuronas y con finalización al conseguir 100 unidades en la capa de salida. La Figura 3 muestra el mapa topográfico de distancias medias, el de distancias medias unificado y el de suma de todas las distancias, obtenidos al finalizar el entrenamiento. Teniendo en cuenta que se está trabajando con píxeles de agua, cuyas firmas espectrales presentan una baja separabilidad, es razonable que sea complicado diferenciar claramente las distintas clases espectrales que pueden existir en la imagen original. En el mapa de distancias medias pueden observarse un conjunto de neuronas en tono azul y otro en tonos cálidos que identificarían claramente a dos clases espectrales diferentes. Existen variaciones tenues de color en el grupo de neuronas azules que podrían indicar la existencia de más clases. El mapa de distancias medias unificado deja entrever esta misma información. Por otro lado, el mapa de suma de todas las distancias muestra que el grupo de neuronas que aparece en tonos azules en el mapa de distancias medias realmente identificaría al menos dos clases espectrales diferentes (aparecen dos grupos de neuronas en colores diferentes). Por lo tanto, cabe pensar que sería posible llegar a distinguir al menos tres clases de aguas en la imagen original.

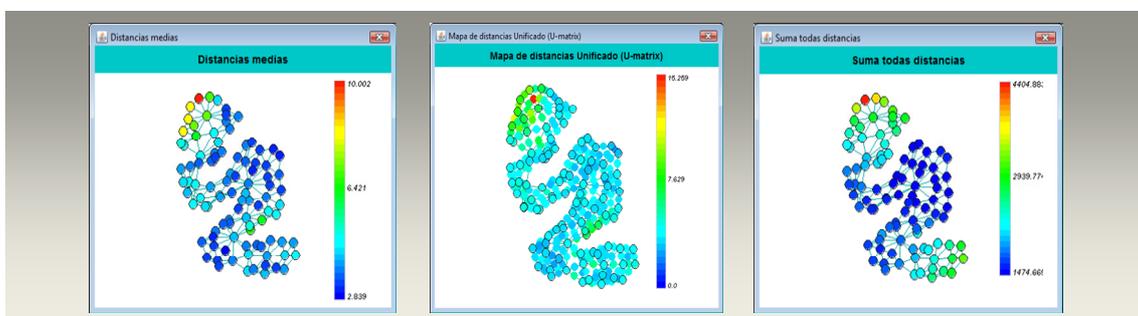


Figura 3. Mapas topográficos. Izquierda: De distancias medias. Centro: Unificado de distancias medias. Derecha: Con suma de todas las distancias.

Usando como base la información de la posible existencia de al menos tres clases de aguas, se entrenó una red GCS con eliminación de neuronas y con criterio de finalización la obtención de al menos tres grupos de neuronas aisladas en la capa de salida de la red. En un primer experimento se obtuvo una red con 109 neuronas organizadas en 4 clusters aislados, y se sometió a la red al proceso de etiquetado no supervisado. La Figura 4 muestra el mapa topográfico de distancias medias de esta red con visualización directa del vector sináptico de cada neurona, así como la etiqueta que se ha asignado a las neuronas de cada cluster (c1, c2, c3 y c4). Dentro de cada cluster de neuronas se ha obtenido la media y la desviación típica de cada uno de los cuatro componentes de los vectores sinápticos de las neuronas que lo forman, lo que representaría la firma espectral media y la

desviación por cada banda de cada una de las cuatro clases de agua detectadas. Esta información queda resumida numérica y gráficamente en la Figura 5. Finalmente, la Figura 6 ofrece la imagen original clasificada utilizando esta red GCS etiquetada. Los píxeles procesados en la primera fase que no se corresponden con agua aparecen en color negro. Los colores de los píxeles de la Figura 6 se corresponden con los de las firmas espectrales de la Figura 5.

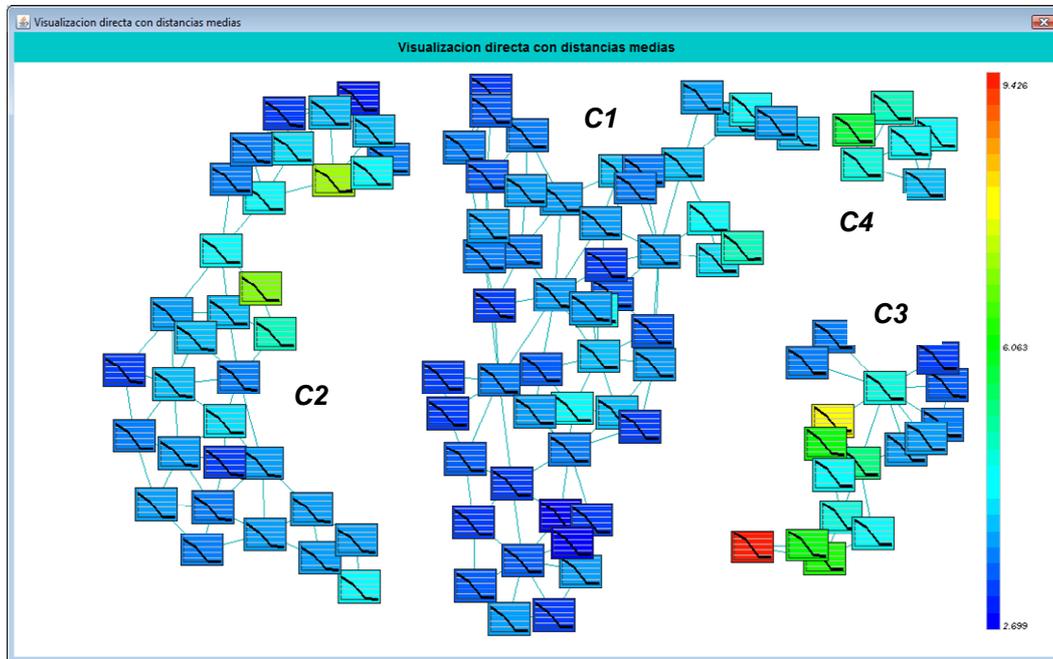


Figura 4. Mapa topográfico de distancias medias con visualización directa del vector sináptico. Red GCS de 4 clusters.

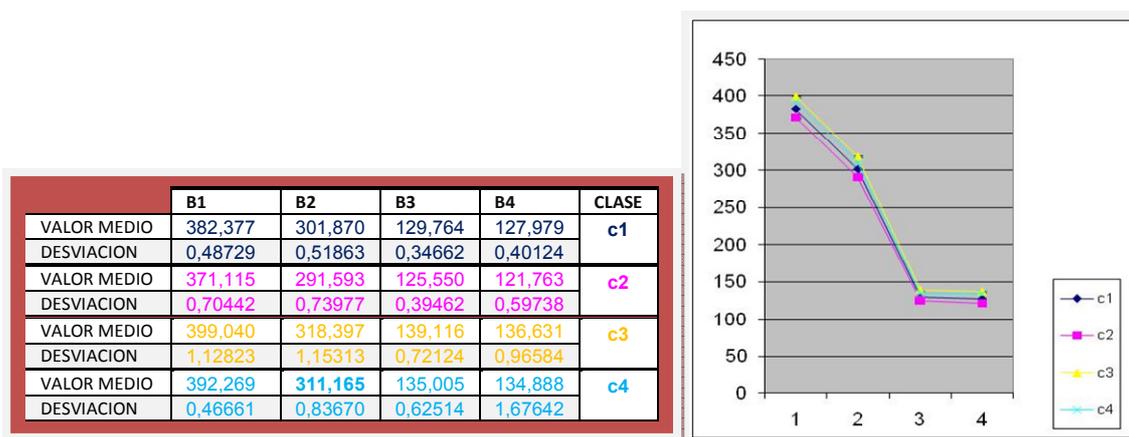


Figura 5. Firma espectral media y desviación típica por componente/banda y cluster. Red GCS de 4 clusters.

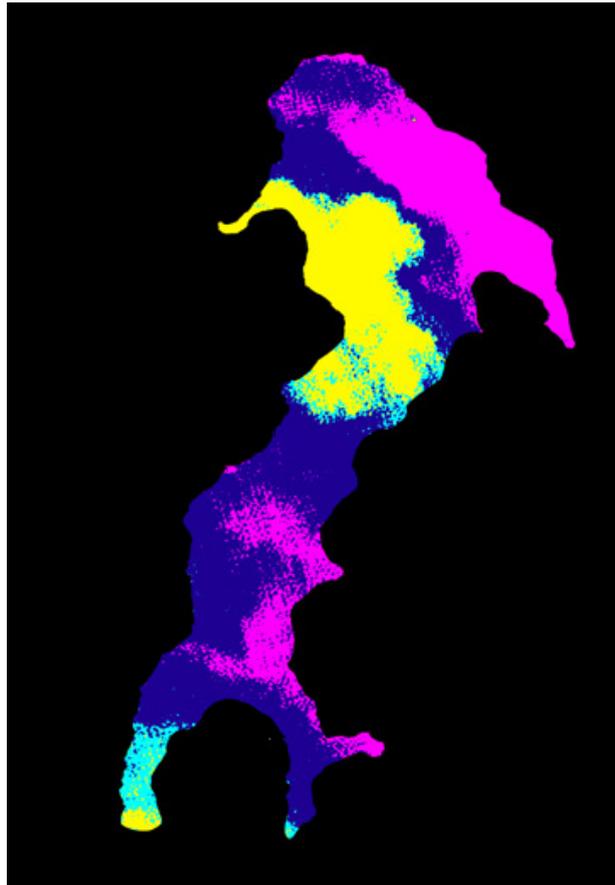


Figura 6. Imagen original clasificada con la red GCS de 4 clusters.

Se han llevado a cabo otros experimentos, entre los que cabe señalar el entrenamiento de otra red GCS, con la imposición de tres clusters aislados en la capa de salida de la red. Se obtuvieron un total de 67 neuronas organizadas en 3 clusters independientes y se sometió a la red al proceso de etiquetado no supervisado. La Figura 7 muestra los valores numéricos y gráficos de las tres firmas espectrales medias y las desviaciones típicas por componente de los vectores sinápticos de las neuronas de cada cluster. Por último, la Figura 8 visualiza la imagen original clasificada usando esta red GCS etiquetada. Los colores de los píxeles de la Figura 8 se corresponden con los de las firmas espectrales de la Figura 7.

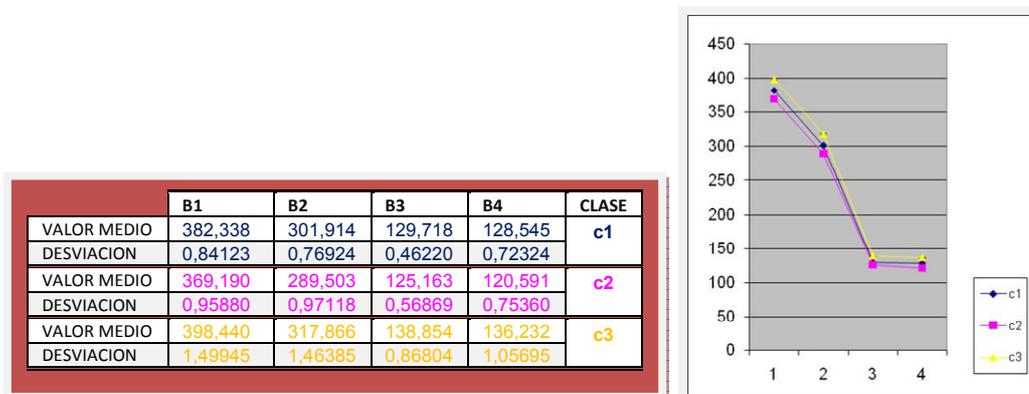


Figura 7. Firma espectral media y desviación típica por componente/banda y cluster. Red GCS de 3 clusters.

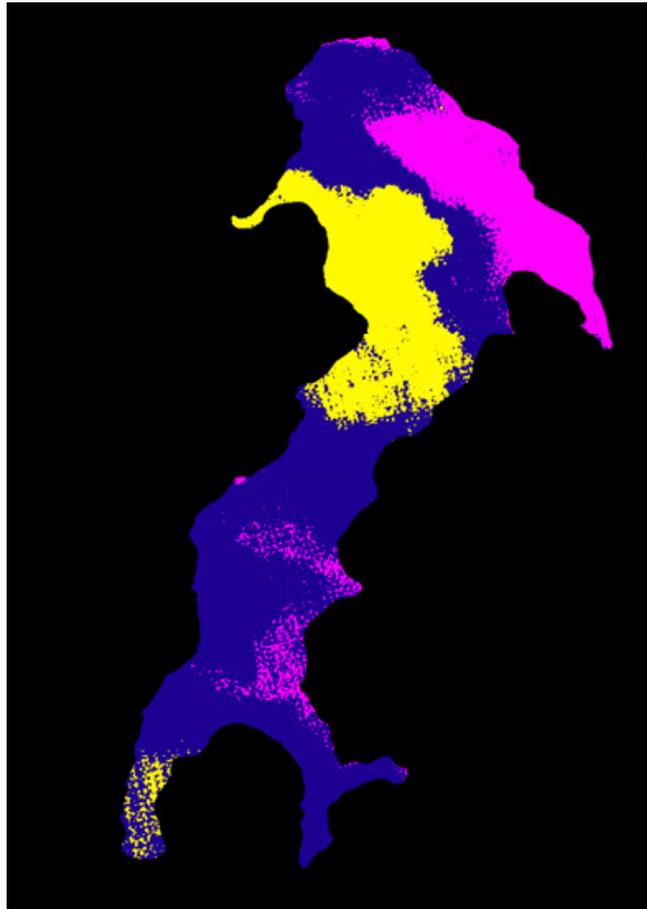


Figura 8. Imagen original clasificada con la red GCS de 3 clusters.

CONCLUSIONES

La utilización de las redes autoorganizativas GCS para obtener modelos simplificados de grandes volúmenes de información permite trabajar con imágenes de satélite de alta resolución, necesarias en tareas específicas como son la separación de cubiertas acuosas con similar respuesta espectral, en un lago. Al tratarse de redes con un aprendizaje no supervisado evitan la necesidad, presente en los métodos supervisados, de seleccionar suficientes áreas de entrenamiento que contengan patrones representativos de los tipos de cubiertas que se deseen discriminar.

La metodología no supervisada expuesta en este trabajo ha demostrado ser una buena herramienta para la detección y clasificación de tipos de aguas. Si bien es necesario indicar en la última fase de la metodología el número mínimo de clusters de neuronas que se desean en la capa de salida de la red, los mapas topográficos de la red GCS, sin eliminación de neuronas, entrenada también en la esta última fase del modelo, ofrecen una valiosa ayuda en este sentido.

BIBLIOGRAFÍA

- [1] Kohonen, T.: Self-organized formation of topologically correct feature maps. *Biological Cybernetics*. 43: 59-69 (1982).
- [2] Ultsch A., Siemon HP.: Kohonen self-organizing feature maps for exploratory data analysis. *Proceedings of the International Neural Network*, Dordrecht, The Netherlands (1990).
- [3] Kraaijveld MA, Mao J, and Jain AK.: A non linear projection method based on Kohonen's topology preserving maps. *IEEE Transactions on Neural Networks* Vol. 6, no.3, 548-559 (1995).
- [4] Merlk D, Rauber A.: Alternative ways for cluster visualization in self-organizing maps. *WSOM'97*, Helsinki, Finland (1997).
- [5] Rubio M, Giménez V.: New methods for self-organizing map visual analysis. *Neural Computation & Applications*. Vol. 12, 142-152 (2003).
- [6] Villmann, T., Der, R., Herrmann, M., and Martinez, T.M.: Topology preservation in self-organizing feature maps: exact definition and measurement. *IEEE transactions on neural networks*, Vol. 8, no. 2, 256-266 (1997).
- [7] Blackmore, J. and Miikkulainen, K.: 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* (1992).
- [8] Burzevski, V. and Mohan, C.K.: Hierarchical growing cell structures. *IEEE International Conference on Neural networks*, New York, NY 3: 1658-1663 (1996).
- [9] Fritzke, B.: Growing cell structures – a self-organizing network for unsupervised and supervised learning. *Neural Networks*. 7, no.1: 1441-1460 (1994).
- [10] Delgado, S., Gonzalo, C., Martinez, E., and Arquero, A.: *Visualizing High-Dimensional Input Data with Growing Self-Organizing Maps*. *Lecture Notes in Computer Science*, Springer, Berlin, 580-587 (2007).
- [11] Delgado, S., Gonzalo, C., Martinez, E., Arquero, A.: Improvement of self-organizing maps with growing capability for goodness evaluation of multispectral training patterns. *IEEE International Proceedings of the Geoscience and Remote Sensing Symposium (IGARSS'04)*, vol 1: 564-567 (2004).