

ESTIMACIÓN DE MAPAS DE TURBIDEZ MEDIANTE GROWING CELL STRUCTURES ENTRENADAS CON IMÁGENES DE ALTA RESOLUCIÓN ESPACIAL Y DATOS DE CAMPO

C. Gonzalo (*), S. Delgado (**), M. Lillo-Saavedra (***) , F. Zambrano (***) , E. Martínez (*) y A. Arquero (*).

(*) DATSI. Facultad de Informática, UPM. 28660 Madrid. chelo@fi.upm.es

(**) Dpto. OEI. Escuela de Informática, UPM. 28031 Madrid.

(***) Dpto. Mecanización y energía. Facultad Ingeniería Agrícola, Univ. Concepción, Chile.

RESUMEN

La estimación de la calidad del agua mediante técnicas de teledetección evita la necesidad de realizar un proceso manual intensivo y continuo que consume recursos, tiempo y que tiene asociados unos altos costes económicos que no aseguran la obtención de buenos resultados. La utilización de técnicas de fusión de imágenes que integran información de la imagen panchromática en la multiespectral, facilitan la posibilidad de manejar datos de mayor resolución espacial que permiten obtener mejores resultados en los procesos de estimación. En este trabajo se presenta la utilización de una técnica no supervisada, las redes neuronales GCS (*Growing Cell Structures*), para estimar los mapas de turbidez de una laguna, y se comparan los resultados de estimación cuando se trabaja con los datos multiespectrales originales y con los fusionados.

ABSTRACT

Water quality estimation using remote sensing techniques avoids the need of an intensive and continuous manual process that consumes resources, time, and has associated high economic costs which do not ensure obtaining good results. Using image fusion techniques that integrate information from the panchromatic image into the multispectral one make it easier to handle data of higher spatial resolution to obtain better results in the estimation process. This paper presents the use of an unsupervised technique, neural GCS (*Growing Cell Structures*) networks, to estimate turbidity maps of a lake, and compares the results of estimation when working with the original multispectral data and the fused one.

Palabras clave: imágenes fusionadas, growing cell structures, turbidez.

INTRODUCCIÓN

El índice de nivel trófico es un indicador de la calidad del agua en lagos u otros reservorios, que se determina a partir de al menos cuatro parámetros: cantidad de nitrógeno y fósforo, turbidez y concentración de clorofila-a (Olmanson, Bauer y Brezonik 2008). Usualmente estas medidas se efectúan *in situ*, recogiendo muestras en diferentes puntos del cuerpo de agua, para posteriormente ser analizadas en laboratorios. Actualmente, existen sondas para obtener estos datos de forma directa, aunque, en cualquier caso, el proceso de recogida de información implica un alto coste económico y de recursos humanos, al que hay que añadir el hecho de que no siempre es posible registrar un volumen suficiente de muestras que estén uniformemente distribuidas.

Diferentes trabajos publicados muestran que una solución complementaria es el uso de técnicas de teledetección, las cuales han permitido la identificación y evaluación de los aspectos más

representativos del proceso de eutrofización, al proporcionar una visión sinóptica, tanto desde un punto de vista espacial como temporal. La precisión de la estimación de las variables estudiadas mediante estas técnicas, depende notablemente de las resoluciones espaciales y espectrales de las imágenes utilizadas. En este sentido, en este estudio, no solo se ha trabajado con imágenes multiespectrales registradas por sensores remotos, sino que también se han utilizado imágenes fusionadas, obtenidas mediante un algoritmo de fusión basado en geometría fractal que integra la información de alta frecuencia procedente de la imagen panchromática de una forma selectiva en la imagen multiespectral.

El objetivo del trabajo es analizar las diferencias en la estimación de mapas de turbidez mediante una metodología basada en las redes neuronales GCS, cuando los datos registrados en el cuerpo de agua son incorporados a las imágenes multiespectrales fuente y a las fusionadas.

METODOLOGÍA

Las redes GCS son un tipo particular de mapa autoorganizativo dinámico, con una única capa de neuronas interrelacionadas por conexiones de vecindad (Delgado *et al.* 2004). En este trabajo se han utilizado como herramienta para la estimación de niveles de turbidez de una laguna, lo que ha requerido alguna modificación de la fase de procesamiento de este modelo, que se expone más adelante. Los patrones de entrenamiento se han definido a partir de los valores espectrales más el dato de turbidez registrado *in situ*, que ha obligado a realizar un proceso de normalización de todos los componentes a un rango común. A partir de las redes entrenadas, ha sido posible estimar la variable turbidez en toda la superficie del lago, empleando únicamente la información espectral de las imágenes de satélite.

En las redes GCS, las neuronas de la capa de salida tienen asociado un vector sináptico de igual dimensión que los patrones de entrenamiento. En el proceso de aprendizaje de la red se consigue un ordenamiento de los patrones de entrada, de forma que las neuronas vecinas responden a vectores de entrada similares, pudiéndose considerar los vectores sinápticos de la red entrenada prototipos de los vectores de entrenamiento. Si la red se entrena buscando clusters aislados de neuronas en la capa de salida, finalmente las neuronas de cada cluster identificarán a tipologías de patrones de entrada. El procesamiento de patrones en una red GCS tradicional entrenada se realiza mediante el cálculo de la distancia Euclídea entre el patrón y todos los vectores sinápticos de la capa de salida, siendo la neurona ganadora, *bmu* (*Best Matching Unit*), la que menor valor obtenga (Delgado *et al.* 2008).

Partiendo de una red entrenada, se han implementado dos métodos distintos de estimación de la turbidez, denominados *bmu* y *cluster*. En ambos se procesan patrones que únicamente incluyen la información multiespectral, de forma que dado un vector de este tipo, la neurona ganadora se obtiene mediante el cálculo de la distancia Euclídea sin considerar el último elemento de los vectores sinápticos de las neuronas de la red, que es el que mantiene el conocimiento de la variable turbidez. Con el método *bmu*, el valor de estimación que se ofrece para el vector procesado es el del último componente del vector sináptico de la neurona ganadora. Por otro lado, el método *cluster* solo es aplicable a redes GCS formadas por diversos clusters aislados de neuronas en la capa de salida. En este caso, la estimación proporcionada es la del

valor medio del último componente de todos los vectores sinápticos que conforman el cluster de la neurona ganadora.

DATOS

Se ha utilizado una escena de 1521x1885 píxeles de una imagen capturada por el sensor multiespectral del satélite SPOT5, con resolución espacial de 5 m. En este trabajo solo se han utilizado las tres primeras bandas. Esta imagen fue registrada el 16 de noviembre de 2008, con coordenadas geográficas de centro de imagen -36,81527 LAT y -73,11308995 LONG, e incluye la laguna de San Pedro localizada en Concepción, Chile. Con fecha 19 de noviembre de 2008 se realizó un proceso de recogida de datos en la laguna, que permitió obtener 57 valores de la variable turbidez registrados en otros tantos puntos de la laguna, distribuidos en toda su extensión. A partir de esta escena multiespectral y su correspondiente imagen pancromática (2.5m), se ha obtenido una imagen fusionada mediante un nuevo paradigma que utiliza mapas locales de dimensión fractal de las imágenes a fusionar (Gonzalo y Lillo 2008), aplicado al conocido algoritmo de fusión basado en la Transformada Discreta Wavelet calculada mediante el algoritmo *à trous*.

Tanto en la imagen fuente como en la fusionada se han obtenido los valores multiespectrales de los 57 puntos en los que se ha registrado la turbidez de la laguna y se han generado los vectores de 4 dimensiones que se han usado para los entrenamientos y testeo de las redes GCS.

EXPERIMENTOS

El 65% de los 57 vectores de 4 dimensiones (R-G-B-Turbidez) tanto del grupo fuente como del fusionado se han empleado para los procesos de entrenamiento de las redes y el 35% restante se han reservado para evaluar el error de estimación generado por estas. Se han dividido los experimentos en dos grandes grupos, por un lado los realizados con los datos fuente y por otro los de los datos fusionados. Para cada uno de ellos se ha procedido a entrenar diversas redes GCS buscando distinto número de clusters aislados de neuronas en la capa de salida, concretamente desde 3 hasta 6. Con cada red entrenada se han aplicado los dos métodos de estimación a los 20 vectores de testeo y se ha calculado el error medio y la desviación estándar en cada caso, comparando los valores estimados con los reales registrados en la laguna. En general, tanto el error medio de estimación de turbidez como la desviación estándar en todos los

casos se encuentra alrededor del 14%, aunque estos valores son ligeramente menores para las redes entrenadas con los datos fusionados.

Aunque se ha realizado una experimentación exhaustiva con los diferentes parámetros, por cuestiones de espacio sólo se exponen los resultados de estimación de la turbidez de la laguna completa obtenidos con algunas de las redes entrenadas. En particular, los generados por las redes que han conseguido 4 y 6 clusters de neuronas en la capa de salida. La Figura 1 ofrece la comparación de estimación de turbidez con el método *bmu*, de las redes de 4 clusters entrenadas con los datos fuente (izquierda) y con los datos fusionados (derecha). Los valores de estimación de turbidez han sido divididos en 10 rangos a los que se les ha asociado un nivel de gris distinto. El gráfico de la parte inferior de la figura ofrece una visión comparativa del volumen de puntos estimados dentro de cada rango, para ambos casos. La Figura 2 muestra esta misma información para las mismas redes, pero usando el método de estimación de turbidez *cluster*. La información comparativa de las dos redes de 6 clusters con estimación de turbidez por *bmu* y por *cluster* queda expuesta en las Figuras 3 y 4, respectivamente.

En todos los casos puede observarse que el mapa de estimación de turbidez de la laguna que se produce al utilizar los datos fusionados no tiene el efecto de pixelado ni de alta variabilidad de estimación que parece producirse cuando se trabaja con los datos originales. Los datos fusionados ofrecen una estimación más suavemente distribuida por zonas de la laguna. Respecto a los métodos *bmu* y *cluster* cabe destacar que el primero, por la metodología que sigue, produce mayor diversidad de estimaciones que el segundo (en el método *bmu* cada neurona determina un valor, mientras que en *cluster* existe una estimación por *cluster* de neuronas), aunque al agrupar los valores en los 10 rangos de niveles de gris los resultados de ambos métodos son similares, tal y como puede observarse en el gráfico de la parte inferior de las cuatro figuras.

CONCLUSIONES

La utilización de un método de estimación de turbidez no supervisado, como son las redes GCS, ofrece la posibilidad de disponer de una herramienta que no precisa de intervenciones de expertos que discriminén o caractericen los datos a procesar.

La naturaleza de las redes GCS permite que durante la fase de entrenamiento la red sea capaz de adquirir y ordenar el conocimiento inherente de los datos para su posterior uso en la fase de estimación.

Los dos métodos de estimación expuestos aplicados sobre la misma red ofrecen resultados diferentes, aunque los errores medios y las desviaciones obtenidas son similares en todos los casos. En principio, el método *bmu* ofrece estimaciones de turbidez distribuidas más uniformemente en los distintos rangos de valores.

La estimación de la turbidez de la laguna usando las imágenes fusionadas consigue mejores resultados que los obtenidos con los datos espectrales originales, distribuyendo más homogéneamente las áreas de estimación y evitando un efecto de pixelado de la imagen que aparece al usar los datos fuente, además de reducir ligeramente los errores de estimación de la variable analizada.

BIBLIOGRAFÍA

- Olmanson, L. G., Bauer, M. E., and Brezonik P. L. 2008. A 20-year landsat water clarity census of minnesota's 10,000 lakes. *Remote Sensing of Environment*, 112(11):4086–4097.
- Delgado, S., Gonzalo, C., Martínez, E., Arquero, A. 2004. 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.
- Delgado, S., Gonzalo, C., Lillo-Saavedra, M., Martínez, E. and Arquero, A. 2008. Uso de redes neuronales autoorganizativas dinámicas no supervisadas para la discriminación de tipos de aguas en lagos. *SELPER'08*.
- Gonzalo, C. and Lillo-Saavedra. M. 2008. Integration of Panchromatic and Multispectral Images by Local Fractal Dimension. *Remote Sensing for a Changing Europe*. In press, EARSEL'08.

