

Interpretación automática de imágenes de satélite NOAA usando técnicas de computación híbrida. Aplicación a la detección del afloramiento canario-sahariano

J.A. Torres (*), A. Fernández (*), F. Guindos (*), M. Peralta (*) y M. Cantón (*)
jtortes@ualm.es

(* G. I. Tratamiento de imágenes. Universidad de Almería. C/. Sacramento s/n. 04120 Almería

RESUMEN: El trabajo presentado resume un prototipo de sistema para interpretación automática de imágenes de satélite NOAA. Este sistema está siendo construido en base a un modelo de conocimiento de tres niveles (nivel de pixel, nivel de estructura y nivel semántico) y usando distintos tipos de técnicas de computación conexionista. Por un lado, hemos usado modelos de redes neuronales que usan información numérica (a nivel de pixel) para la realización de tareas de enmascaramiento de nubes, y por otro, hemos desarrollado técnicas de computación conexionista que manipulan vectores de entrada con información sobre cualidades de regiones para realizar tareas de interpretación de imágenes. En el presente trabajo se expone un resultado parcial del sistema en el que se muestra un proceso de detección de zonas del afloramiento en el NO de Africa usando esta técnica. Los resultados indican que el procedimiento es adecuado para el desarrollo de un futuro sistema de interpretación automática en imágenes de satélite.

ABSTRACT: The presented work shown a prototype of an automatic interpretation system of NOAA satellite images. This system is being build using a three levels knowledge model (pixel level, region level and domain problem semantic level) and it uses several connectionist computational approaches. For a first time, we have used the artificial neural nets models (into the pixel level) to make basic preprocessing tasks as cloud masking. By other way, we have developed a new connectionist technique that uses input vectors with non numerical features about sea regions. This model is used into the identification phase. The present work shown a partial result on identification tasks of upwelling zones over NOAA infrared images of the NW of African coast. This results light a procedure to develop a future ocean automatic interpretation system on satellite images.

Palabras clave: Teledetección, interpretación automática, redes neuronales, computación híbrida, AVHRR.

INTRODUCCIÓN

Durante las pasadas tres décadas el número de satélites de observación y gestión de recursos terrestres ha incrementado la cantidad de información recibida en forma de imágenes de la Tierra. En la actualidad, la mayor parte de ésta reside almacenada sin que el coste de su análisis e interpretación permita su análisis: Se calcula que más del 80% de las imágenes se encuentran sin procesar.

Por otro lado, su descripción y estudio se realiza mediante intérpretes humanos, lo que ralentiza y subjetiviza dicho proceso. Por lo tanto, sería deseable que en ciertas aplicaciones la interpretación de las imágenes dejase de ser manual y pudiese realizarse de forma automática, lo que permitiría entre otras cosas la realización de búsquedas inteligentes en bases de datos de imágenes y la mejora en la selección de datos de interés.

El problema de la identificación de estructuras oceánicas en imágenes de satélite puede

considerarse un problema susceptible de ser resuelto usando técnicas de inteligencia artificial por varios motivos:

1. Las estructuras oceánicas presentan un grado de variabilidad térmica y morfológica que hace prácticamente imposible la construcción de un procedimiento algorítmico tradicional que incorpore la cantidad de imponderables que se presentan en una imagen real de satélite.
2. El proceso de identificación está influido por un factor contextual muy importante: La medición de valores de temperatura o de características de una región dan lugar a estructuras distintas en función del lugar geográfico y de la fecha en la que se encuentren.

En el trabajo propuesto se abordan estos y otros problemas realizando una descomposición del problema desde el punto de vista del conocimiento en tres niveles: nivel de conocimiento de pixel, nivel de regiones, y nivel de relación y posición entre regiones.

Nivel de conocimiento de pixel

En este nivel la información que podemos obtener es la del valor asociado al pixel (que, para este sistema en particular hemos usado la temperatura de brillo, por presentar con mayor detalle las diferencias entre distintas estructuras oceánicas) y medidas que relacionan a un pixel con sus vecinos. Las medidas estadísticas de centralización y los valores de variabilidad son usados para la detección inicial de algún elemento constitutivo de la imagen. Un ejemplo es la medida de variabilidad dada por la expresión

$$x_2 \equiv r^d(i, j) = \left\{ \left\{ \begin{array}{l} x(i, j) \neq x(k, l) \\ x(k, l) \in \text{img4} : \quad \wedge \\ \text{dist}(x(i, j), x(k, l)) \leq d \end{array} \right\} \right\}$$

donde $x(k, l)$ y $x(i, j)$ son valores de intensidad en la banda 4, img4 es la banda 4 de la escena AVHRR sobre la que se va a realizar el proceso de identificación, d es un número que indica una distancia en pixeles y dist es una función de cómputo de distancia. Esta medida es útil en la detección de nubes en AVHRR (Torres et al. 1998).

Nivel de conocimiento de regiones

En este nivel vamos a establecer aquellas características relativas a las regiones del océano obtenidas a partir de un procedimiento de segmentación. En este nivel surgen características de alto nivel, ó simplemente características no numéricas que hay que considerar en el proceso de identificación. En este nivel usamos un modelo de procesamiento basado en simular el comportamiento de una red neuronal artificial, con entradas no numéricas.

Nivel de conocimiento de relación entre regiones

El análisis realizado a este nivel incorpora información sobre la posición geográfica de las regiones detectadas en el nivel anterior. Una base de conocimiento y una nueva red neuronal que procesa este conocimiento realizará un proceso de interpretación final.

METODOLOGIA

El sistema propuesto usa información de las bandas 2 y 4 del NOAA para realizar el proceso de identificación de estructuras oceánicas (figura 1).

Como se puede observar, la parte de detección para enmascaramiento o para interpretación corre a cargo de modelos de redes neuronales artificiales y un modelo de computación adaptado que proviene de éstas.

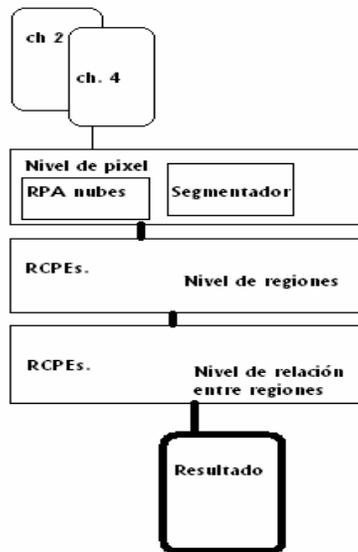


Figura 1.- Diagrama del sistema automático de identificación.

Redes neuronales artificiales

las redes neuronales artificiales se han mostrado como herramientas muy valiosas cuando se aplican en procesos de clasificación sobre datos de satélite. En general:

1. Los sistemas de computación neuronal son útiles cuando el problema maneja un conocimiento escaso, cambiante y variable en el tiempo.
2. Las técnicas convencionales de clasificación de patrones no proporcionan niveles de precisión altos en muchas aplicaciones de teledetección, con conjuntos de datos complicados (tratamiento de imágenes en series de tiempo, espectrometría, etc.) (Kanellopoulos et al. 1992).

Una red neuronal está formada por un conjunto de elementos de procesamiento (PEs.) cuyo funcionamiento viene dado por la expresión:

$$S_i = \psi_i(A_i(\sum_j w_{ij}x_j))$$

donde A_i es la **función de activación de la neurona** y ψ_i es la **función de salida**. Al valor $\sum_j w_{ij}x_j$ se le conoce como **entrada neta** y está compuesta por la suma de las entradas (x_j) ponderada con los pesos de interconexión (w_{ij}) que relacionan a este PE con otros.

Las redes de propagación hacia atrás (RPA) son un caso particular de estructuras de estos elementos básicos de procesamiento (figura 2).

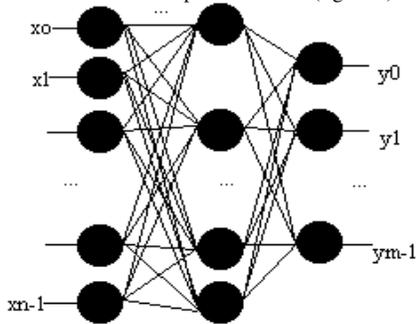


Figura 2.- Estructura de una RPA.

Haykin, 1994 define tres características de la RPA:

1. La función de salida es no lineal: usualmente una sigmoide.

$$\psi_i = \frac{1}{1 + e^{-neta_i}}$$

donde \$neta_i\$ es la entrada neta asociada a la neurona \$i\$

2. La red tiene un nivel de PEs de entrada, uno o varios ocultos y uno de salida.
3. La red está totalmente conectada.

Una RPA clasifica si existe un proceso de aprendizaje que modifica los pesos de interconexión entre los distintos PEs. El algoritmo de entrenamiento es una técnica de minimización de una función de error expresada por

$$E_{avg} = \frac{1}{k} \sum_j^m (y_j - d_j)^2$$

donde \$y_j\$ es la salida \$j\$-ésima de la red y \$d_j\$ la salida deseada.

Para realizar el proceso de ajuste de los pesos se sigue la función iterativa:

$$w_{ji}(t) = w_{ji}(t-1) + \eta \delta_j y_i$$

donde \$\eta\$ se denomina parámetro de aprendizaje, \$\delta_j\$ es la medida de error dependiente del nivel del PE y \$y_i\$ es la salida de este PE en ese instante de tiempo.

Un modelo de RPA ha sido usado en el nivel de conocimiento de pixel para el enmascaramiento automático de estructuras nubosas usando información de los canales 2 y 4 del AVHRR.

Modelo de computación conexionista con entradas no numéricas

El modelo presentado es un sistema de manipulación de símbolos que permite clasificar vectores de características con valores no numéricos a partir de un proceso de entrenamiento.

Al no disponer de ninguna información acerca de la estructura de los conjuntos a los que pertenecen las entradas el sistema basará todo su conocimiento en un principio de imitación basado en ejemplos (figura 3). Este principio se traduce en nuestro caso en dos principios de acción:

1. El sistema sólo reconoce como entradas válidas aquellas que se asemejen a las que se han utilizado en el proceso de entrenamiento (principio de activación).
2. El sistema reconoce como salida frente a una entrada válida aquella que más se asemeje a la salida producida por entradas parecidas en el proceso de entrenamiento (principio de decisión).

En torno a estos dos principios se puede construir un PE que procese información simbólica y sobre el que es susceptible de aplicar alguna técnica de entrenamiento. En particular, para este trabajo hemos desarrollado un PE que selecciona producciones de una base de información en base a reglas que determinan el nivel de activación de este y la salida que se encuentra más relacionada con un determinado vector de entradas. Cada una de estas reglas tiene una prioridad, por lo que es posible construir una superestructura competitiva (red competitiva de PEs) que permita clasificar las distintas regiones de la imagen analizando la salida de cada uno de los PEs y determinando cual es la "mejor".

El sistema desarrollado dispone de una red competitiva que tiene 4 PEs que desarrollan labores de interpretación de regiones. Uno de ellos está especializado en localizar posibles zonas de afloramiento.

El sistema ha sido desarrollado en el entorno Matlab usando una máquina UNIX SPARC, y probado usando imágenes AVHRR sobre las que se ha realizado un preprocesamiento inicial (temperatura de brillo y enmascaramiento de tierra y

nubes), así como un escalado en niveles de grises en el rango [0,255].

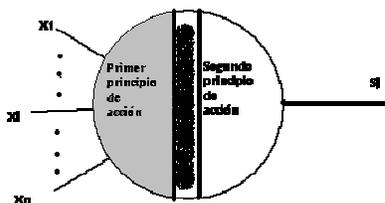


Figura 3.- Actuación de los dos principios de acción dentro de un PE.

RESULTADOS

Los datos de satélite corresponden a una escena del 3 de agosto 1993 (figura 4), sobre la zona de Canarias y costa sahariana y el resultado se muestra en la siguiente figura. El sistema detecta la posible zona de influencia del afloramiento y otras estructuras oceánicas, sin intervención alguna de operador humano.

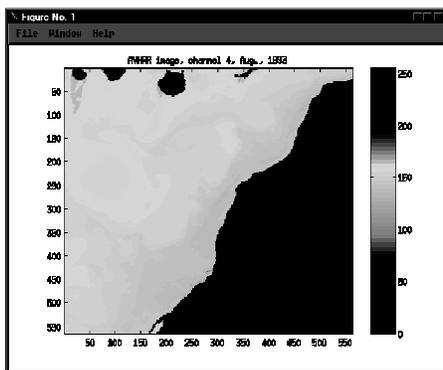


Figura 4.- Canal 4 de una escena AVHRR sobre la zona de Islas Canarias.

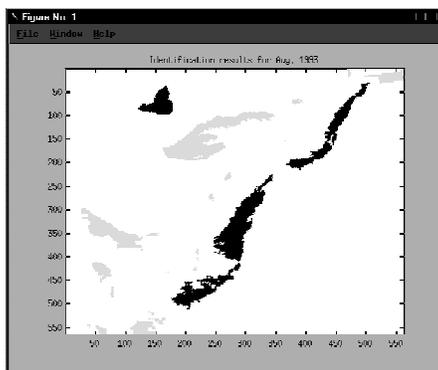


Figura 5.- Resultado de la interpretación automática. En oscuro el núcleo del afloramiento, en claro la zona de influencia de este, en medio tono, algunas estructuras filamentosas.

BIBLIOGRAFIA

- [1] Augustejn, M. F., 1992. Dimalanta, A. S.. "Feature detection in satellite images using neural networks technology". Telematics and Informatics, Vol. 9, 3-4, p. 131-144.
- [2] Haykin, S., 1994. "Neural Networks, A Comprehensive Foundation", Macmillan Publisher Company, NY. Ch. 6 p. 138-139.
- [3] Kanellopoulos, Y., Varfis, A., 1991. "Classification of remotely sensed satellite images using multi-layer perceptron networks". Artificial Neural Networks, p. 1067-1071.
- [4] Peak, J. E., Tag, P. M., 1994. "Segmentation of Satellite Imagery Using Hierarchical Thresholding and Neural Networks". Journal of Applied Meteorology, Vol. 33, 5, p. 605-616.
- [5] Torres, J. A., Guindos, F., Peralta, M., Fernandez, A. Cantón, M, Parada, M. García, L., Tejera, A., 1997. "Enmascaramiento automático de estructuras nubosa en imágenes de satélite AVHRR usando modelos de computacion neuronal". VIII Simposio Iberoamericano sobre Percepción Remota, SELPER. Merida, Venezuela.

AGRADECIMIENTOS

A los doctores Luis García Weil y Antonio Juan Ramos de los departamentos de Física Aplicada y de Biología, de la Universidad de Las Palmas por la selección de las imágenes para su procesamiento.

Este trabajo ha sido realizado con la financiación del proyecto CICYT. MAR97-0464-C04.