

## CLASIFICACIÓN EN TIEMPO REAL DE IMÁGENES METEOROLÓGICAS MEDIANTE REDES NEURONALES

F. J. TAPIADOR (\*) y J.L. CASANOVA (\*\*)

javier@tapiador.com

(\*) Actualmente, University of Birmingham. School of Geography and Environmental Sciences. UK.  
Anteriormente, LATUV

(\*\*) Universidad de Valladolid. Departamento de Física Aplicada I.  
Laboratorio de Teledetección (LATUV)

**RESUMEN:** En este trabajo se presenta un sistema automático de clasificación en tiempo real de imágenes meteorológicas utilizando una red neuronal de tipo ART-MAP. Se señalan los aspectos relevantes de la investigación previa, mostrando los tipos de redes ensayados (ART1, ART2, ART-MAP, PNN, etc.), las características de cada una de ellas y las capacidades de la red elegida. Asimismo, se explicita la estructura del sistema de trabajo en tiempo real, y las potencialidades futuras de esta tecnología en este campo. Por último, se señala la componente SIG del sistema, vertebrada en torno a la capacidad de integrar los productos en sistemas multipropósito, y en la propia gestión de los datos.

**Palabras clave:** Redes neuronales, meteorología, GIS.

**ABSTRACT:** An ART-MAP NN based-automatic classification system in real time for meteorological imagery is presented. The relevant topics in previous research are pointed out and the NN tested (ART1, ART2, ART-MAP, PNN and others) is showed. The architecture of the system is also presented with the GIS relationship in order to highlight integration in multipurpose systems and data management. Future trends and perspectives are also underlined.

**Keywords:** Neural Networks, Meteorology, GIS

### INTRODUCCIÓN

La capacidad de las redes neuronales para ejecutar tareas de clasificación ha quedado sobradamente demostrada en los últimos años (Benediktsson, 1990). En el campo de la Geografía, diversos autores han mostrado las capacidades de esta metodología para hacer frente a problemas complejos (Openshaw *et al.*, 1994), lo que viene a mostrar la necesidad de utilizar modelos cuantitativos para el análisis de la realidad geográfica. En este sentido, la clasificación de imágenes procedentes de satélites, ya sea para su uso directo en meteorología o en climatología, es hoy en día una tarea que requiere una automatización completa para que posea algún valor científico (Openshaw, comunicación personal 2000)

En este trabajo se presenta de forma somera un sistema automático sobre UNIX, capaz de realizar las tareas más complejas de clasificación de imágenes de satélite en tiempo real, en concreto METEOSAT, NOAA-

AVHRR y FENG-YUNG, aunque con posibilidad de adaptación casi inmediata a otros sensores. Se muestra una parte de la fase de diseño e implantación, los análisis realizados para la elección de la red neuronal más adecuada, y la estructura del sistema resultante, así como sus capacidades.

### ANÁLISIS Y ELECCIÓN DE LA RED NEURONAL

La explotación de una imagen meteorológica de satélite requiere en muchos casos de una primera diferenciación de los elementos singulares que las conforman, ya sea la clásica división tripartita entre tierra, agua y nubes, u otras más complejas, como la propia diferenciación nefelógica. El sistema destinado a realizar la clasificación ha de contar con dos propiedades básicas: su celeridad y su precisión. Celeridad, porque, en el caso del METEOSAT, la resolución temporal permite la utilización de los datos elaborados como insumos de mo-

delos climáticos, o como elementos de un sistema experto destinado a la evaluación del riesgo natural, situación que se agudiza con la mayor precisión inmediata de la segunda generación de este programa espacial. La precisión es necesaria por las propias características de los modelos, por lo general de alta componente estocástica, y por lo tanto, sensibles a las condiciones iniciales que se le proporcionen. En otros campos en los que las imágenes de estos satélites pueden ser útiles, ambas propiedades son también deseables, ya sea para la estimación de precipitaciones en lapsos mayores que +72, o para la integración de los resultados en modelos agroclimatológicos. Por otro lado, cualquier método posible había de contar con la posibilidad de su automatización, con la menor intervención humana posible.

Así pues, dado el estado tecnológico actual al respecto, se consideró oportuno enfocar el sistema de clasificación en dos direcciones: el uso de lógica borrosa, lo que ofreció buenos resultados, y las redes neuronales, cuyas capacidades se mostraron superiores en la fase de evaluación. Una vez que se optó por esta vía, se procedió a analizar las posibles estructuras capaces de satisfacer los caracteres privativos de las imágenes de satélite. En concreto, se analizaron los siguientes modelos, adaptándolos en algunos casos:

- BPN (Backpropagation network)
- BCN (Boltzmann Completion Network)
- BION (Boltzmann Input-Output Network)
- BFN (Boltzmann Feedforward Network)
- CCN (Cauchy Completion Network)
- CION (Cauchy Input-Output Network)
- CFN (Cauchy Feedforward Network)
- PNN (Probabilistic Neural Network)
- GRNN (General Regresion Neural Network).
- GCNN (Gram-Charlier Neural Network)
- QNN (Quadratic Neural Network)
- DLVQ (Dinamic Learning Vector Quantization)
- CC (Cascade Correlation Algorithm)
- TDNN (Time Delay Neural Network)
- RBF (Radial Basis Function)
- ART 1 (Adaptative Resonance Theory 1)
- ART 2 (Adaptative Resonance Theory 2)
- ARTMAP (Adaptative Resonance Theory)
- SOM (Self Organizing Maps)

Los resultados obtenidos mostraron que *a priori* las mejores capacidades se obtenían con una red ARTMAP capaz de llegar a resultados borrosos, por lo que se procedió a un estudio exhaustivo de este modelo y de las posibilidades de implantación, teniendo muy en cuenta la variable temporal del sistema.

## DESCRIPCIÓN DE LA RED

La red neuronal posee la estructura mostrada en la figura 1. Como toda red ARTMAP consta de tres módulos diferenciados: dos complejos ART, y un *mapfield* que las interconecta y que es vital para sus capacidades. El número de pilas que forman el núcleo de las zona oculta se obtuvo mediante prueba y error, llegándose a la conclusión de que la estructura resultante era la más adecuada. Tanto los parámetros de inicialización como de aprendizaje y el parámetro de vigilancia de la red se obtuvieron al cabo de decenas de pruebas, ante la ausencia de criterios en la bibliografía actual, como han señalado diversos autores (e.g. Carpenter *et al.*, 1998) al respecto. Un elemento que se consideró de interés fue la consecución de un nivel de error muy bajo sin contar con un conjunto de datos de entrenamiento elevado. De hecho, se trabajó con del orden de 15 patrones para cada clase, correspondientes cada uno de ellos a un vector *n*-dimensional, con *n* el número de bandas de partida, lo cual se puede considerar exiguo. Esta decisión se llevó a cabo con objeto de facilitar una puesta a punto rápida de la red, posibilitando al operador que con tan sólo unos pocos datos de entrada la red ejecute sus tareas con solvencia, tarea que por otra parte tan sólo se debe llevar a cabo de tarde en tarde, dadas las buenas prestaciones. Los tiempos de entrenamiento son típicamente de minutos.

Una vez que la red estuvo entrenada con un grado de fiabilidad adecuado, se procedió a la poda de su estructura, evaluando a su vez cinco algoritmos.

- Poda basada en la magnitud
- Daño cerebral óptimo
- Daño cerebral óptimo con la matriz de Hesse
- Esqueletización
- Axones no-contributivos

El modelo elegido fue el de esqueletización. Los resultados obtenidos en cuanto a estructura son en la actualidad objeto de estudio, aunque se puede avanzar que existe una tendencia notable a potenciar la información procedente de algunas bandas en detrimento de otras, en relación directa con las componentes principales de la imagen, lo que da como resultado un sesgo hacia los sectores involucrados en su análisis directo.




Figura 1. Red Neuronal ARTMAP.

### ESTRUCTURA DEL SISTEMA

El sistema consta de un núcleo programado en ANSI-C que es el que forma la red neuronal, bajo UNIX. El resto de la estructura lo conforman un conjunto de programas escritos en PERL encargados de ejecutar secuencialmente las siguientes tareas:

- Transferencia automática de ficheros desde las máquinas que almacena las imágenes de las antenas receptoras, inmediatamente después de la captura.
- Calibración y corrección atmosférica de las imágenes.
- Partición en paquetes de las bandas como insumos de la red.
- Transformación en el modelo de entrada a la red neuronal: datos-prueba.
- Paso de los datos-prueba por la red.
- Extracción de los resultados y adecuación de formato.
- Conversión automática a diferentes formatos: raw, jpeg, bil, bip, gif, bmp, etc., en función de las necesidades.
- Almacenado de la información relevante.
- Plasmación en las X de las imágenes mediante combinación RGB ecualizada para su evaluación visual directa.
- Envío de la información al SIG para su integración y manejo.

El sistema establece una interconexión directa con un SIG que le sirve de medio de visualización e integración de la información con otro tipo de datos, de satélite

y de campo, como por ejemplo los sondeos o los productos derivados de los modelos digitales de elevaciones. Por otro lado, se puede entender al sistema como un SIG, un sistema unitario en el que la red neuronal ejerce el papel de módulo de análisis geográfico. Este último punto de vista, entendiendo al SIG como (CAD+BD+Análisis Geográfico), marca de hecho la línea de trabajo en SIG que se está realizando.

### RESULTADOS

El grado de fiabilidad obtenido es tributario de una estructura robusta, probada con éxito en la teoría y con tradición en clasificación de imágenes (Carpenter 1998). De un conjunto de datos de validación del doble de tamaño que los datos de entrenamiento se obtuvieron aciertos del orden de 98.4% en el caso de METEOSAT y del 99.4% para NOAA-AVHRR, utilizando tres posibles clases. Los datos de validación se obtuvieron por métodos interactivos, no automáticos.

En el caso de diferenciación de clases de nubes se pueden establecer umbrales de pertenencia, dados los caracteres borrosos del sistema. La fiabilidad en este caso se reduce, tanto por la dificultad intrínseca que supone la clasificación como por la propia elección de vectores de entrenamiento, mucho más discrecional por parte del técnico, aunque en todo caso ronda el 95%. Como muestra de estos dos procedimientos, se ofrece la figura 2, en la que se aprecian los resultados para una imagen NOAA-AVHRR del golfo de Cádiz en marzo de 2000, sin el procesado ulterior en clases estancas para mayor claridad.

Por último, en la detección automática de eventos susceptibles de conformar precipitaciones de alta intensidad horaria, lo que supone una de las aplicaciones de mayor interés, aparecen buenas perspectivas, que no pueden ser calibradas aún con precisión ante la carencia de series que doten de significación estadística a los resultados, siendo éste un campo en el que se trabaja actualmente dentro del LATUV. Dados los caracteres del sistema, residente en una máquina en funcionamiento constante y trabajando de manera automática, la posibilidad de que este sistema pueda ser usado en cooperación con sistemas expertos para la toma de decisiones sobre los riesgos naturales en tiempo real aparece como uno de los hitos del sistema. Como apunte, señalar que el sistema puede ser adaptado con muy poco esfuerzo para realizar otro tipo de tareas no directamente vinculadas con la meteorología, como la realización de clasificaciones para la confección de mapas de usos del suelo.





Figura 2. Imagen NOAA-AVHRR (canal 2), clasificación en 3 y 7 clases, respectivamente.

## CONCLUSIONES Y PERSPECTIVAS

Se ha descrito un sistema operativo para el trabajo el tiempo real con imágenes meteorológicas, automático y preciso, formado en torno a una red neuronal ARTMAP, y con una componente SIG importante en su vertiente de análisis geográfico. Se han señalado sus características, sus prestaciones y los resultados que se pueden obtener con él, así como algunos de los trabajos que se llevan a cabo de manera rutinaria con su ayuda. Por último, se ha indicado su multifuncionalidad en otros campos de la Teledetección.

Las perspectivas del sistema se bifurcan en tres direcciones principales: abrir el sistema al exterior mediante una simple *interface* de introducción de datos / recepción de resultados, y profundizar en la estructura de la red, investigando otras arquitecturas y algoritmos para problemas más complejos, en concreto de análisis de movimiento. También se ha iniciado una línea en relación con el análisis de los resultados propiamente dichos, tanto a nivel meteorológico como climatológico.

## BIBLIOGRAFÍA

- BENEDIKTSSON, J.A., P.H. SWAIN y otros, 1990. *Neural networks approaches versus statistical methods in classification of multisource remote sensing data*. IEEE Trans. of Geosc. and RS 28(4).
- CARPENTER G.A., MILENOVA, B.L., NOESKE, B.W. 1998. *Distributed ARTMAP: a neural network for fast distributed supervised learning*. Neural Networks, 11.
- OPENSHAW, S. 1994. *Neuroclassification of spatial data*. En *Neural Nets: Applications in Geography*. Hewitson y Crane Eds. Kluwer Academic Publishers.

## AGRADECIMIENTOS

A Joaquín Ferrero por sus recursos en PERL y UNIX, y a Kamal Al-Rawi por sus indicaciones y recursos sobre redes neuronales.