

DetECCIÓN Y RECONOCIMIENTO DE ESTRUCTURAS OCEÁNICAS EN IMÁGENES AVHRR EN EL ÁREA DE LAS ISLAS CANARIAS Y NO DE AFRICA MEDIANTE TÉCNICAS DE COMPUTACIÓN CONEXIONISTA

J. A. Torres y M. Cantón

jtorres@ualm.es

Grupo de investigación Tratamiento de imágenes. Universidad de Almería. C/ Sacramento, s/n. 04120 Almería

RESUMEN

En este artículo presentamos algunos resultados obtenidos en interpretación automática de imágenes AVHRR. Dichos resultados se han obtenido a partir de un prototipo de sistema que usa un modelo de conocimiento de tres niveles (nivel de pixel, nivel de estructura y nivel semántico) y 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. Los resultados muestran una habilidad del sistema para identificar la presencia de ciertas estructuras oceánicas (afloramiento, giros y estelas) en el NO de África e Islas Canarias. Los modelos de descripción de estructuras y la estructura de los algoritmos de identificación parecen adecuados como elementos constitutivos de un sistema de interpretación automática en imágenes de satélite.

PALABRAS CLAVE: Teledetección, interpretación automática, redes neuronales, computación híbrida, AVHRR.

ABSTRACT

The presented work shown a prototype of an automatic interpretation system of AVHRR 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 several artificial neural net models (into the pixellevel) 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 several oceanic structures (wakes, upwelling and eddies) in infrared images of fue NW African coast and Canary Island. These results light a procedure to improve an otean automatic interpretation system on satellite images.

KEY WORDS: Remote Sensing, automatic interpretation, neural nets, hybrid computation, 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 procesamiento e interpretación permita su análisis: de hecho existe gran cantidad de información que no ha sido procesada aún.

La principal causa de ésto radica en lo costoso del proceso de interpretación, fundamentalmente debido a que la descripción y estudio de esta información se realiza mediante intérpretes humanos, lo que ralentiza dicho proceso.

En la actualidad, el uso intensivo y extensivo de los datos de satélite apunta a la necesidad de poder disponer de un sistema automático de consulta y

recuperación de imágenes en función de su contenido.

En general 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 es un problema difícil en el que se acumulan una serie de factores que lo alejan de su posible solución mediante técnicas de computación clásicas:

1. Las estructuras oceánicas presentan un grado de variabilidad térmica y morfológica que hace prácticamente imposible la construcción de un modelo matemático que incorpore la

cantidad de variables 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. Un ejemplo lo podemos encontrar en el afloramiento sahariano y en el frente Almería-Orán, que presentan características morfológicas similares pero que son en realidad estructuras muy distintas.

En el trabajo propuesto se abordan éstos 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.

AREA DE TRABAJO DEL SISTEMA DE IDENTIFICACION AUTOMATICA

La región del NO de África sobre la que se la que se va a realizar el estudio se encuentra enclavada en la parte más oriental del Atlántico oriental. (GarcíaWeil, 1998) realiza una detallada descripción oceanográfica de ella.

Esta zona está influenciada principalmente por el Giro Subtropical del Atlántico Norte, constituyendo su parte oriental. Esta parte del bucle se caracteriza por tener en su límite superior la Corriente de Azores que conduce el agua hacia el Este.

La acción de los vientos alisios produce en este flujo un cambio de dirección hacia el SO, generando la corriente de Canarias. Cuando esta masa de agua se acerca a la costa, su dinámica se modifica de manera importante como consecuencia de la acción de los vientos alisios, generando un *afloramiento costero*.

En la zona de transición costera se producen interesantes fenómenos de tipo mesoescalar que son objeto de estudio por el sistema de identificación. En particular, la corriente de Canarias, al acercarse a las costas africanas presenta en su borde *estructuras filamentosas y giros fríos*. Cuando dicha corriente es interrumpida por el archipiélago canario, se producen fenómenos de turbulencia que generan *giros ciclónicos y anticiclónicos* alrededor de las islas.

METODOLOGIA

Para alcanzar el objetivo de interpretar de forma automática una imagen se ha trabajado en dos campos: un modelo de conocimiento a tres niveles, en los que la imagen se representa en distintos espacios de representación del conocimiento, y un sistema de clasificadores que actúan sobre ese conocimiento (Figura 1), generando conocimiento

de un nivel superior o proporcionando una interpretación de la imagen.

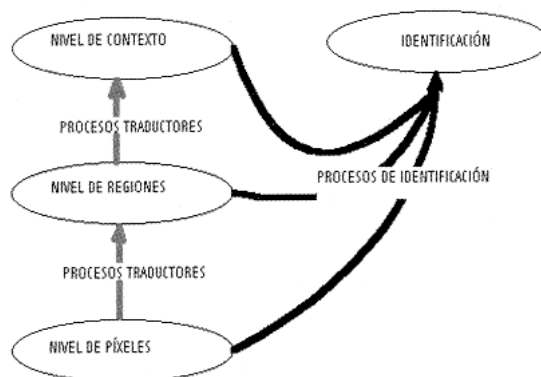


Figura 1. Estructura de conocimiento y de manipulación de éste en el sistema de interpretación de imágenes AVHRR.

Niveles de conocimiento

La abstracción del conocimiento de un problema en distintos niveles se considera usualmente una buena regla heurística en el diseño de sistemas de inteligencia artificial. El sistema propuesto diferencia el conocimiento en este problema en tres niveles:

1. Nivel de píxeles.
2. Nivel de regiones.
3. Nivel de relaciones entre regiones y contexto geográfico de éstas.

Nivel de conocimiento de pixel

En este nivel, la información que podemos obtener es la del valor asociado al pixel (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

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

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 píxeles y dist es una función de cómputo de distancia. Esta medida es útil en la detec-

ción de nubes en imágenes AVHRR (Torres et al, 1997) (Torres et al, 1999).

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 se encuentra información 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, así como características relacionadas con la posición de la región en la imagen.

Técnicas de clasificación

El fundamento de las técnicas usadas en el proceso de identificación de estructuras oceánicas se basa en el hecho de que la información que se maneja en el dominio del problema es difícil de formalizar. En estos casos parece razonable usar una aproximación que construya la solución del problema en base a conocimiento acerca de particularizaciones del fenómeno a identificar.

Entre las técnicas de inteligencia artificial para la resolución de problemas en base a ejemplos se encuentran los clasificadores neuronales y los sistemas de razonamiento basados en casos.

Ambas técnicas han sido usadas en el desarrollo de este trabajo en distintas fases del proceso 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 neuronales 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 de alta variabilidad y alto número de descriptores (tratamiento de imágenes en series de tiempo, espectrometría, etc.) (Kanellopoulos et al, 1991).

Una red neuronal está formada por un conjunto de elementos de procesamiento (PEs) que calculan de manera individual, una función dependiente de las entradas a éste y que se interconectan entre sí formando mallas con capacidad de aprendizaje.

La disposición de los distintos elementos de procesamiento y la arquitectura de interconexión entre éstos da lugar a distintos tipos de clasificadores neuronales.

En este trabajo hemos usado fundamentalmente tres tipos de redes: las redes de propagación hacia atrás, los mapas autoorganizativos y las estructuras LVQ. Estas tres arquitecturas de clasificadores neuronales han sido usadas intensivamente en el campo de la Teledetección (Lybanon et al, 1990), (Hung et al, 1992), (Molinelli et al, 1992), (Peak et al, 1994), (Augusteijn, 1991), (Chakraborty et al, 1993).

El uso que se le ha dado en este trabajo está relacionado con labores de identificación a bajo nivel (procesamiento en el nivel de píxeles y de relaciones entre estos), en labores de construcción de la máscara de nubes, y en labores de análisis de perfiles térmicos de regiones, en los que se pretenden detectar estructuras convexas y cóncavas con ciertos tipos de sesgo.

Mapas autoorganizativos

Los mapas autoorganizativos son sistemas neuronales de cómputo que hacen uso de un tipo de aprendizaje competitivo y no supervisado.

(Kohonen, 1990) y (Kohonen, 1995) describen la estructura de un mapa autoorganizativo, formado por los siguientes elementos:

1. Un conjunto de elementos de procesamiento organizados en un sistema uni o bidimensional de cómputo.
2. Una función de cómputo de un valor discriminante dependiente de las entradas.
3. Un mecanismo de selección de la neurona con mayor valor discriminante, el grupo de neuronas próximas a ésta, y un procedimiento de adaptación de estas funciones para que incrementen el valor discriminante para las neuronas seleccionadas.

Los mapas autoorganizativos presentan una interesante propiedad: una vez entrenado el mapa la disposición de los vectores representativos de cada una de las neuronas forman una malla o retícula en el espacio de entradas que tiene que ver con el grado de identificación de una determinada característica en el espacio de entradas.

Una de las características más interesantes de este tipo de sistemas conexionistas es la relación entre la localización espacial de una neurona en el mapa topográfico y una característica o dominio particular del vector de entrada. Esta relación es

conocida como el *principio de la formación del mapa topográfico* (Kohonen, 1990).

LVQ (Leaming Vector Quantization)

El modelo LVQ (Figura 2) puede considerarse una modificación sobre un sistema autoorganizativo con dos niveles diferenciados:

- Un mapa autoorganizativo que lleva a cabo la labor inicial de identificación de agrupaciones de patrones.
- Una red supervisada que toma como entrada la partición realizada por el mapa autoorganizativo y proporciona como salida la partición especificada en el problema.

El sistema permite asignar una etiqueta de clase a cada uno de las agrupaciones generadas en el mapa autoorganizativo, gracias a la parte supervisada de la estructura.

Redes de propagación hacia atrás

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

Una RPA está formada por un nivel de neuronas de entrada, uno o varios niveles de neuronas en capas intermedias (denominadas ocultas) y un nivel de neuronas de salida (Haykin, 1994). En el nivel oculto se almacena, en forma de ponderación de las conexiones entre neuronas, el conocimiento obtenido mediante entrenamiento (Figura 3).

Una RPA clasifica si existe un proceso de




Figura 2. Estructura LVQ. Se aprecia la matriz competitiva sobre la que se inserta un nivel supervisado.

aprendizaje que modifica los pesos de interconexión entre los distintos PE. El algoritmo de entrenamiento es una técnica de minimización de una función de error expresada por:

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

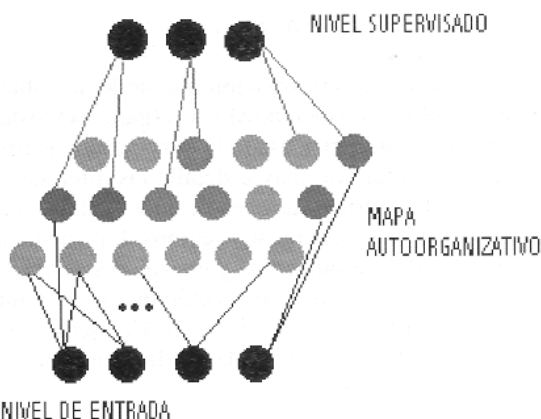


Figura 3. Estructura de una red de propagación hacia atrás.

donde y_j es la salida j -ésima de la red, d_j la salida deseada y k es una constante.

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 (Torres et al, 1997).

Modelo de computación conexionista con entradas no numéricas

El trabajo con vectores de características que incorporan información no numérica ha sido abordado usando un modelo de clasificador con estructura y comportamiento derivada de los sistemas expertos y las redes neuronales.

El clasificador propuesto tiene como elemento fundamental de cálculo una unidad de procesamiento simbólico (EPS) que maneja conocimiento siguiendo técnicas de razonamiento por casos. Este EPS dispone internamente de una base de conocimiento (proporcionada en una etapa de entrenamiento) y de un conjunto de reglas que manipulan este conocimiento y eligen una salida acorde con la información de entrenamiento del sistema (Figura 4).

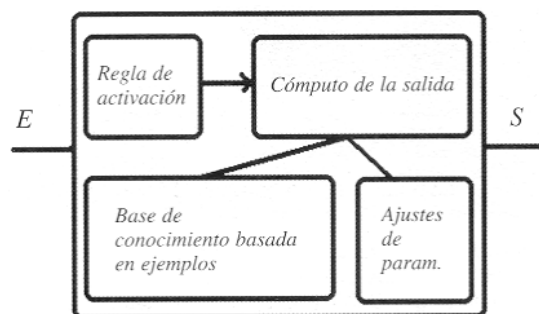


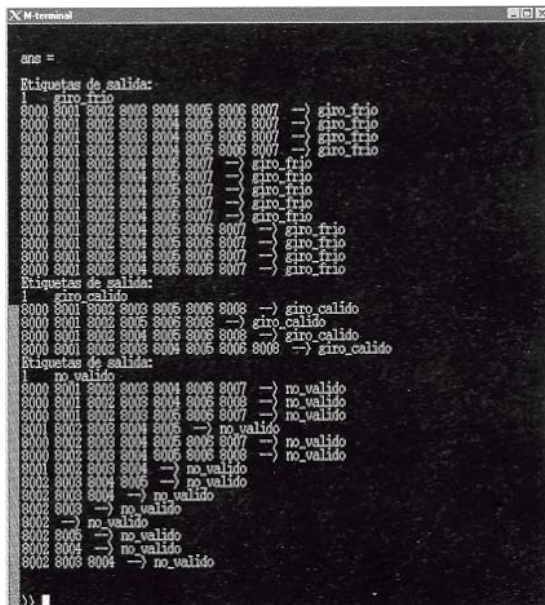
Figura 4. Estructura de un Elemento de Procesamiento Simbólico. Un EPS dispone internamente de un mecanismo que activa el EPS en función de la entrada, una base de conocimiento (inducida mediante entrenamiento), un manipulador de conocimiento en base a reglas, que computa la salida y un conocimiento acerca de la precedencia en la aplicación de estas reglas.

El modelo de cómputo se basa en un *principio de imitación basado en ejemplos*. 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).

El funcionamiento del EPS es como sigue: dado un vector de características de entrada, determina si existe un vector similar en el conjunto de entrenamiento (un ejemplo de este tipo de conjuntos lo tenemos en la Figura 5). En ese caso, y en base a unas reglas, decide cuál es la salida teniendo en cuenta las salidas producidas en el proceso de entrenamiento ante vectores de entrada similares. El resultado es una etiqueta de salida así como un valor numérico asociado a la regla que se ha usado para generar dicha salida.



```
ans =
Etiquetas de salida:
1
giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
8000 8001 8002 8003 8004 8005 8006 8007 -> giro frio
Etiquetas de salida:
1
giro caliente
8000 8001 8002 8003 8004 8005 8006 8008 -> giro caliente
8000 8001 8002 8003 8004 8005 8008 -> giro caliente
8000 8001 8002 8003 8004 8005 8006 8008 -> giro caliente
8000 8001 8002 8003 8004 8005 8006 8008 -> giro caliente
Etiquetas de salida:
1
no valido
8000 8001 8002 8003 8004 8006 8007 -> no valido
8000 8001 8002 8003 8004 8006 8008 -> no valido
8000 8001 8002 8003 8005 8006 8007 -> no valido
8001 8002 8003 8004 8005 -> no valido
8000 8002 8003 8004 8005 8006 8007 -> no valido
8000 8002 8003 8004 8005 8006 8008 -> no valido
8001 8002 8003 8004 -> no valido
8002 8003 8004 8005 -> no valido
8002 8003 8004 -> no valido
8002 8003 8004 -> no valido
8002 -> no valido
8002 8003 -> no valido
8002 8003 -> no valido
8002 8004 -> no valido
8002 8005 8004 -> no valido
```

Figura 5. La información de la base de conocimiento en el EPS se encuentra descrita por medio de expresiones como las de la figura.

Los EPS se organizan a su vez en estructuras competitivas sobre las que una función de decisión elige cuál es la salida final del sistema tomando en cuenta no sólo las salidas de cada EPS de la estructura competitiva, sino también la regla asociada con éstas.

Estructura e implementación del sistema

La primera versión de este sistema (que presentamos aquí) está formada por un conjunto de estructuras competitivas de EPS. Cada uno de estos EPS dispone de información relacionada con un

tipo de estructura oceánica (afloramiento, giros y estelas fundamentalmente) así como información de "falsas estructuras" producidas por formaciones nubosas o por información confusa de la superficie del mar. Cada EPS ha sido entrenado con estructuras tipo localizadas en imágenes de distintas fechas.

El sistema dispone así mismo de un detector de regiones por umbralizado sucesivo en todo el rango radiométrico. Este proceso es posterior a un proceso de enmascaramiento automático de nubes usando la técnica desarrollada en (Torres et al, 1999).

Las regiones generadas por el detector son descritas en los distintos niveles de conocimiento e interpretadas por los clasificadores.

La implementación ha sido desarrollada 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), así como un escalado en niveles de grises en el rango [0,255].

RESULTADOS

El sistema, en su versión actual, ha sido probado sobre 70 imágenes de distintas zonas geográficas obteniendo resultados de identificación de estructuras oceánicas bastante esperanzadores.

El sistema funciona bastante bien (100% de acierto en la detección de presencia) en la detección de zonas de influencia del afloramiento para regiones con tamaño máximo cercano a 150.000 Km². Este límite queda impuesto por la capacidad de cómputo del ordenador.

En las Figuras 6, 7 y 8 podemos ver la detección de la zona de influencia del afloramiento en la que se aprecian varias estructuras filamentosas.

Las zonas de influencia de los afloramientos se detectan incluso cuando la cobertura nubosa afecta directamente a la costa NO de África, siempre que el porcentaje de costa libre (y con presencia de afloramiento) sea sensiblemente superior al de cobertura nubosa. Cuando la cobertura nubosa es muy elevada y afecta de manera importante a la zona de influencia del afloramiento, el sistema puede presentar identificaciones de esta zona cuya extensión no se corresponda con la realidad.

En las imágenes procesadas se detectan estelas al S y SO de las islas Canarias.

La detección de este tipo de estructuras está limitada, para esta primera versión (y por problemas de capacidad de cómputo), a aquellas con tamaño comprendido entre 500 y 3.500 Km². En imágenes de cobertura nubosa de baja extensión, la presencia de estelas es identificada con una precisión del 80%.

El sistema de identificación es muy sensible en este caso a imperfecciones de la máscara de tierra. Si ésta no se encuentra correctamente localizada, los datos AVHRR correspondientes a las zonas de

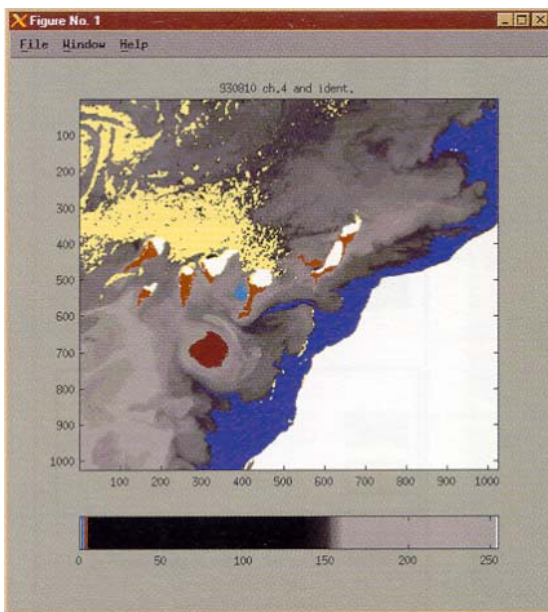


Figura 6. Imagen AVHRR del archipiélago canario y costa NO de África tomada el 10 de Agosto de 1993, donde, como resultado de la interpretación, se puede apreciar la identificación de un giro cálido (en rojo) un giro frío (en azul claro), estelas y una marca del afloramiento.




Figura 7. Imagen de la misma zona tomada el 7 de Junio de 1987, en la que se pueden observar además la presencia de un giro al SO de Gran Canaria. Las estelas presentan cierta dificultad

tierra no enmascaradas provocan que el sistema informe de "falsas estelas" que circundan las islas.

En las Figuras 6, 7 y 8 podemos ver la detección estelas en las distintas islas del archipiélago canario. Las Figuras 6 y 7 presentan, cerca de Fuerteventura y Tenerife respectivamente una prolongación de las zonas de estelas hacia el Oeste y hacia el Norte producidas por un fallo en el enmascaramiento de tierra de la imagen. En la Figura 8 se puede apreciar una situación límite en la que la cobertura nubosa afecta ya, y de manera importante, a la zona costera de las islas. El sistema, no

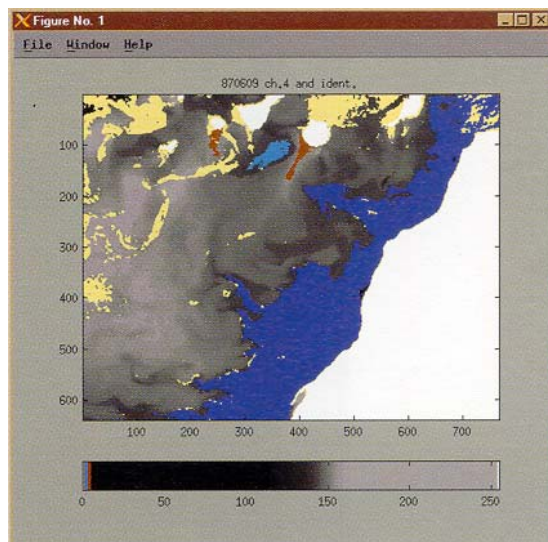


Figura 8. Interpretación de una imagen AVHRR tomada el 9 de Junio de 1987 en la misma zona.

obstante, puede todavía identificar estas estructuras.

Las estructuras oceánicas que presentan mayor nivel de dificultad para su detección son los giros (en sus distintas manifestaciones). Para estas estructuras el sistema presenta niveles de precisión en la detección de giros cercanos al 80%.

Para esta primera versión del sistema, el conocimiento aportado permite detectar giros que se presenten aislados del resto del agua circundante (regiones más o menos redondeadas que se presenten aisladas en el proceso de construcción de regiones) que presente uno o varios núcleos diferenciados y que, en función de la manifestación de éste (giro frío o cálido) se presente a determinada distancia de islas o de la costa.

Por otro lado para que la detección sea efectiva, el giro no puede encontrarse en la frontera de la imagen ni estar afectado por la cobertura nubosa.

Las Figuras 6, 7 y 8 presentan la detección de un giro cálido, al Sur de Tenerife y del giro frío en el SO de Gran Canaria. El sistema, en otras imágenes, ha detectado giros al O de la Gomera y un pequeño giro cálido al E de Fuerteventura.

En general, en imágenes con cobertura nubosa concentrada y porcentualmente pequeña con respecto al total de la imagen, se detectan con relativa precisión la presencia de afloramientos, giros fríos, giros cálidos y estelas (al Sur del archipiélago canario).

El nivel de precisión ronda el 80% (siempre que estas estructuras no se encuentren afectadas por la cobertura nubosa o por deformaciones derivadas de la corrección geométrica de la imagen).

En situaciones de cobertura nubosa extendida a lo largo de toda la imagen la identificación no se produce cuando las regiones candidatas están tocadas por la máscara nubosa, debido a la influencia que ésta ejerce sobre la morfología de las regiones.

Además, el sistema ha sido probado en otras zonas geográficas, detectando afloramientos en la

costa portuguesa y distintos tipos de giros cerca de la costa cantábrica y en el Mediterráneo. Esto nos sugiere que el sistema pueda aplicarse, con cambios mínimos, a distintas zonas geográficas.

Por último, la inserción de conocimiento relacionado con las estructuras ya conocidas y de otras que no han sido mencionadas es un proceso muy sencillo y que no altera la capacidad de identificación ya adquirida. De tal forma, el sistema puede aprender en base a la información que extraiga de sucesivas imágenes.

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.

BIBLIOGRAFÍA

- AUGUSTEIJN, M. F., DIMALANTA, A. S. 1991. Feature detection in satellite images using neural networks technology. *Telematics and Informatics*. 9 (3-4): 131-144.
- CHAKRABORTY, G., KUDOH, J., SHIRATORI, N., NOGUCHI, S. 1993. Classification of NOAA Satellite Image Data by Unsupervised Neural Network. *Trans. on the Society of Instrument and Control Engineers*. 29 (3): 281-287.
- GARCÍA WEIL, L. 1998. Descripción y análisis cuantitativo mediante series de imágenes de satélite de la dinámica de las aguas superficiales del NO de África. *Tesis Doctoral*. Universidad de Las Palmas de Gran Canaria.
- HAYKIN, S. 1994. *Neural Networks, A Comprehensive Foundation*, Macmillan Publisher Company, NY. Ch. 6 p. 138-139.
- HUNG, S. L., CHENG, A. Y. S., LEE, V. C. S. 1992. Neural net classifier for satellite imageries. *Proc. of the SPIE-International Society for Optical Engineering*, Vol. 1709, Iss: pt. 1 p. 269-74.
- KANELLOPOULOS, Y., VARFIS, A., 1991. Classification of remotely sensed satellite images using multilayer perceptron networks. *Artificial Neural Networks*, p. 1067-1071.
- KOHONEN, T. 1990. The self-Organizing Map. *Proc. of the IEEE*. 78 (9): 1.464-1.480.
- KOHONEN, T. 1995. *The self-Organizing Map*. Ed. SpringerVerlag.
- LYBANON, M., MOLINELLI, E., FLANIGAN, M. 1990. Automatic description of the Gulf Stream from IR images using neural networks. Application of Artificial Neural Networks, *SPIE*. 1.294: 225-237.
- MOLINELLI, E., MUNCILL, G., KEVIN, P. 1992. Progress with Neural Network Gulf Stream. Final technical rept. *Performer: Planning Systems Inc.*, McLean, VA. 52p.
- PEAK, J. E., TAG, P. M. 1994. Segmentation of Satellite Imagery Using Hierarchical Thresholding and Neural Networks. *Journal of Applied Meteorology*. 33 (5): 605-616.
- TORRES, J. A., FERNÁNDEZ, A., GUINDOS, F., PERALTA, M., CANTÓN, M. 1999. Mejoras en las técnicas de enmascaramiento de nubes en imágenes AVHRR. *Actas del VIII Congreso Nacional de Teledetección*. p. 387-390, Albacete.
- 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 computación neuronal. *VIII Simposio Iberoamericano sobre Percepción Remota (edición electrónica)*, SELPER. Merida, Venezuela.