

Análisis automático de imágenes oceánicas de satélite mediante sistemas basados en conocimiento

F. Guindos, J. A. Piedra y M. Cantón
fguindos@terra.es

Universidad de Almería. Dpto. de Lenguajes y Computación. 04120 Almería

RESUMEN

Las imágenes que nos llegan de los satélites se han convertido en una fuente primordial de información sobre nuestro entorno. Se trata de información "en bruto" que necesita de expertos para ser aprovechada al máximo. Pero los expertos no son muchos y el trabajo es ingente, por lo que la solución del problema en la recopilación de la experiencia humana en sistemas automáticos que hagan el mismo trabajo.

En este trabajo se presenta la estructura de un sistema basado en conocimiento capaz de reemplazar a un experto cuando se entrena adecuadamente. De esta forma se ha construido un sistema de reconocimiento automático que procesa imágenes AVHRR de los satélites NOAA para detectar fenómenos oceánicos de interés como afloramientos, giros y estelas de islas.

El sistema se ha entrenado con información tanto general como localizada y ha demostrado sus cualidades con imágenes de las costas Canarias, Mediterránea y Cantábrica.

PALABRAS CLAVE: análisis de imágenes, teledetección oceanográfica, sistemas expertos.

ABSTRACT

Images received from satellites have become a great source of information about our environment. This is raw information that needs experts to make the most of it, but there are not many experts and the work is too much. The solution to this problem is the compilation of human experience into automatic systems that could do the same work.

We depict here the structure for a knowledge based system capable of taking the place of human experts when it is properly trained. This structure has been used to build an automatic recognition system that process AVHRR images from NOAA satellites to detect and locate ocean phenomena of interest like upwellings, eddies and island wakes.

The automatic knowledge driven image-processing system has been trained with ubiquitous and localized information and has proved his qualities with images of Canary Island, Mediterranean Sea and Cantabric and Portuguese coasts.

KEY WORDS: image analysis, ocean remote sensing, knowledge systems.

INTRODUCCIÓN

Durante las últimas tres décadas, el volumen de datos sobre la Tierra recibido de los satélites de observación ha sido enorme. Actualmente, la mayor parte de esta información se almacena en los centros de recepción sin ser interpretadas porque se necesita de un experto para ello. Este problema es de particular importancia en las imágenes de fenómenos meso y macroescalares del océano. La dificultad para el análisis de estas imágenes radica fundamentalmente en la falta de un modelo matemático preciso que describa estas estructuras y su variabilidad. En este trabajo se muestran los resultados obtenidos en un sistema de interpretación automática de imágenes AVHRR diseñado para localizar estructuras mesoescalares oceánicas. El sistema se ha diseñado con el objetivo de eliminar toda intervención humana.

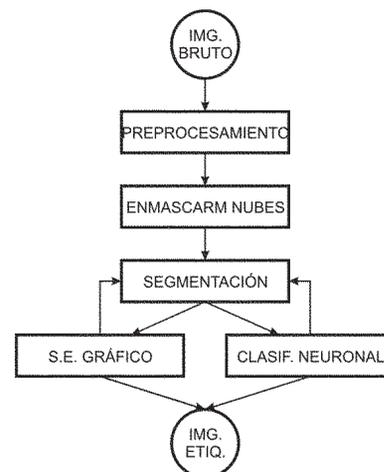


Figura 1. Estructura del sistema de reconocimiento de estructuras oceánicas.

F. Guindos, J. A. Piedra y M. Cantón

ESTRUCTURA GENERAL DEL SISTEMA

En la Figura 1 se muestra la estructura general del sistema. En un primer paso, la imagen en bruto se procesa con algoritmos tales como corrección radiométrica, proyección y enmascaramiento de tierra. Son técnicas bien conocidas y que también se usan cuando el análisis está a cargo de los expertos.

La segunda tarea consiste en la eliminación de las zonas nubosas donde la medida de los sensores AVHRR no es válida. Se aplica un valor nulo o de ceros a cada pixel de las áreas afectadas.

La siguiente fase es la segmentación, que divide la imagen en regiones. La idea es que cada fenómeno de interés debería coincidir con una o unas pocas regiones. La naturaleza de la dinámica oceánica hace de éste un trabajo muy difícil que, sin embargo, es fundamental. Por este motivo, para implementarlo se ha diseñado un método iterativo basado en conocimiento.

La última fase es la de reconocimiento. Cada región obtenida en la segmentación se analiza y, si el reconocimiento es positivo, se etiqueta con el identificador de la estructura correspondiente. Las estructuras de interés en la zona de las Islas Canarias, tal como se definen en Arístegui *et al.* (1994) son: 1) Afloramiento costero. 2) Giros cálidos. 3) Giros fríos. 4) Estelas de islas. La gran mayoría de las regiones producidas en la segmentación carecen de interés especial y se etiquetan con 0.

El subssistema de reconocimiento implementado incluye un elemento de procesamiento simbólico basado en redes neuronales y un sistema experto gráfico basado en reglas actuando de forma redundante. De esta forma se pueden validar los resultados de la fase más importante del proceso.

ESQUEMA DE PROCESO DETALLADO

Enmascaramiento de nubes

La técnica utilizada se detalla en Torres *et al.* (2003a). La idea básica es considerar que cada píxel posee una o ambas de las siguientes características: a) valor muy bajo en la banda 4 comparado con sus vecinos b) alta variabilidad.

El sistema explota esta idea localizando una primera estimación de los píxeles afectados por ambas características o muy fuertemente por una de ellas. En

un segundo paso, el sistema incorpora un refinamiento de la máscara basado en la reflectividad (un valor alto en la banda 2).

La implementación se ha hecho utilizando dos redes neuronales con retropropagación. La primera se usa para crear un mapa de píxeles candidatos y la segunda realiza la selección final a partir de este mapa.

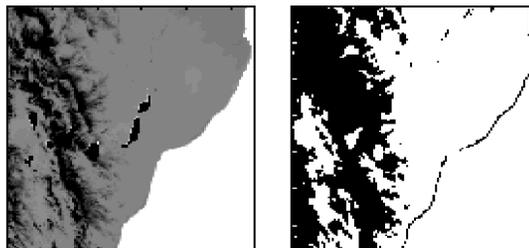


Figura 2. Escena AVHRR y máscara de nubes.

Los resultados de esta fase se muestran en la Figura 2, donde se ve una escena AVHRR nubosa de las Islas Canarias tomada por el satélite NOAA-14 y la máscara resultante que, cuando se superpone sobre la imagen original evita el procesamiento posterior de los píxeles etiquetados como “nube”.

Segmentación

La segmentación es un elemento clave en todo sistema de procesamiento automático de imágenes. Los resultados finales sólo serán válidos si se consigue una segmentación de buena calidad. Sin embargo, como se explica en Guindos *et al.* (2001) y Thonet *et al.* (1995), las imágenes AVHRR del océano son muy difíciles de segmentar debido a una elevada variabilidad en el valor de los píxeles, lo que se traduce en resultados pobres cuando se usan técnicas basadas exclusivamente en gradientes o texturas. El método propuesto en Guindos *et al.* (2001) utiliza líneas isotermas que se ha comprobado que producen mejores resultados en segmentaciones de este tipo de imágenes. Este método, como cualquier otra segmentación basada en umbrales, adolece del problema inherente de la selección del umbral, que se ha resuelto aplicando el conocimiento adquirido en la siguiente fase creando un proceso iterativo.

El umbral inicial para la segmentación se puede fijar como la media aritmética del los valores de los píxeles de agua. Con este umbral se realiza la segmentación y los resultados se pasan a la siguiente

fase que analiza cada región. Entonces, basándose en el conocimiento sobre cada tipo de región buscada, el umbral puede ser incrementado o reducido y se realiza una nueva segmentación. Cada vez que se producen unos resultados se comparan con los anteriores y el sistema determina si el cambio fue en la dirección adecuada, se debe hacer en el sentido contrario o debe quedarse con el valor anterior y terminar la tarea. Una segmentación se considera mejor que la anterior si las regiones que encajan en una clase de interés tienen un área mayor.

Con este método se consiguen buenas segmentaciones en imágenes AVHRR, con regiones compactas y se reduce la sobresegmentación obtenida con otros métodos probados (*watersheds* (Beucher, 1990) y Canny (Canny, 1983)). En la Figura 3 se muestra un ejemplo.

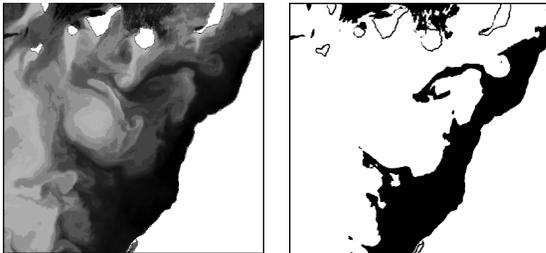


Figura 3. Segmentación de una escena AVHRR.

Clasificación

Clasificador neuronal

El clasificador neuronal está construido en tres niveles de conocimiento (píxel, región y contextual). En el nivel del píxel utiliza los valores de la banda 4 de las imágenes AVHRR. En el nivel de región se calculan características morfológicas. En el tercer nivel, el contextual, se añade información geográfica.

Esta información pasa a un clasificador competitivo de alto nivel que utiliza el conocimiento de forma no numérica para establecer la clase más cercana a cada región. El proceso detallado se puede ver en Torres *et al.* (2003b).

Sistema experto gráfico

El sistema experto gráfico (SEG) trabaja como un oceanógrafo y recopila el conocimiento sobre el océano expresado en forma de reglas de producción. También filtra la información que llega al SEG para limitarla a aquella relevante para el reconocimiento de las estructuras oceánicas presentes en la imagen.

Para recopilar el conocimiento necesario para este componente, cada fenómeno oceánico de interés ha de ser definido por un experto humanomediante descriptores numéricos o simbólicos.

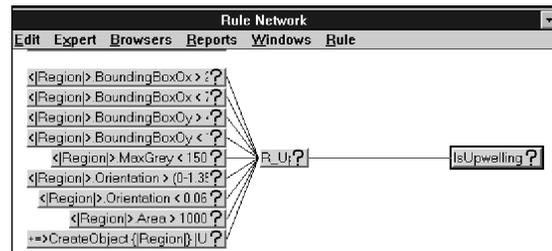


Figura 4. Ejemplo de regla de producción.

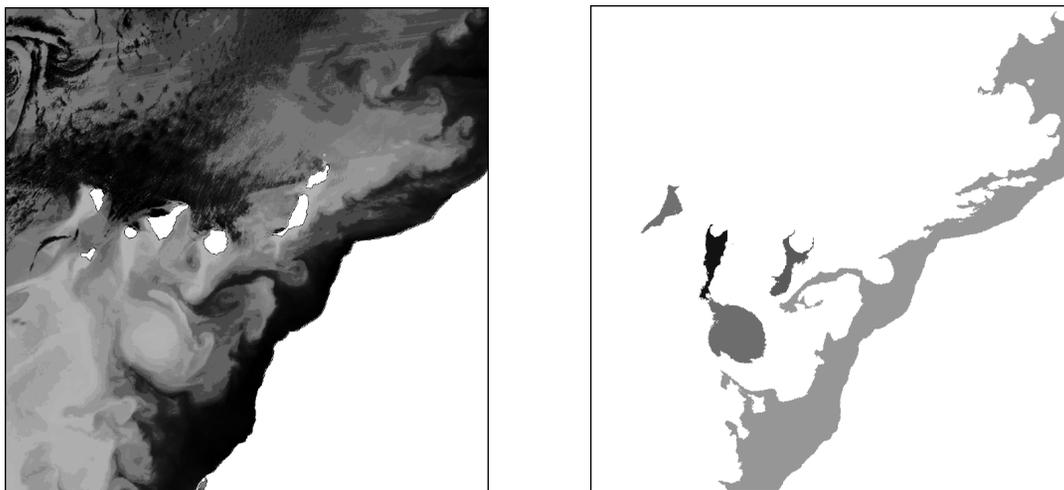
Cada elemento de esta información se puede referir a una región por sí misma (como “tamaño” o “temperatura”) o en relación con otras regiones (como “más frío que...”). Habitualmente, el conocimiento se basa en características bien conocidas, pero pueden aparecer otras más elaboradas como momentos o la varianza.

Los expertos humanos suelen usar valores simbólicos como “pequeño” o “grande” que han de ser comparados con valores calculados numéricamente a partir del valor de los píxeles, por lo que la relación entre ellos tiene que ser definida mediante intervalos. Este conocimiento se traduce a reglas de producción (Figura 4) que conforman el núcleo del proceso.

Lo difícil de esta tarea es identificar el esquema de deducción, impreciso y a veces intuitivo, que utilizan los expertos humanos para realizar esta labor. Igualmente, la inexistencia de un modelo exacto para cada estructura de interés del problema puede conducir a lagunas o inconsistencias en el conocimiento que el experto aporta al sistema. Este es un problema general en los sistemas expertos por lo que se han desarrollado técnicas que operan con este tipo de conocimiento incompleto o impreciso (redes bayesianas o técnicas difusas (Intan *et al.*, 2002)).

En nuestro sistema, la solución adoptada ha sido considerar que las hipótesis no son probadas de forma absoluta cuando las condiciones de laguna de sus reglas son ciertas. En su lugar, se añade cierta verosimilitud, que se va acumulando a través de los ciclos del proceso iterativo de segmentación-reconocimiento.

F. Guindos, J. A. Piedra y M. Cantón



*Figura 5. (a) Imagen AVHRR (ecualizada) y (b) mapa de estructuras de interés.

PRODUCTO FINAL

La información producida por las unidades de proceso basadas en conocimiento (sistema experto gráfico y red neuronal) se combinan en una nueva imagen (Figura 5) que muestra de modo visual cada estructura de interés detectada. Las estructuras se identifican mediante diferentes colores en el mapa.

En un último paso, el mapa de estructuras se puede superponer a la imagen original (Figura 6). Para esto se utiliza el código de color que identifica cada elemento de la máscara, pero aquí, para obtener una imagen impresa mejor apreciable, se ha usado una máscara negra en todos los casos.

RESULTADOS

El sistema ha sido probado con un conjunto de 36 imágenes AVHRR con distintos grados de cobertura nubosa, desde unas con el cielo totalmente despejado hasta otras en las que las nubes las dejan prácticamente inutilizables. Los resultados obtenidos se muestran en la Tabla 1:

	Experto humano	Sistema automático
Afloramiento	29	29
Giros fríos	3	2
Giros cálidos	4	4
Estelas	48	48

Tabla 1. Comparación entre el Sistema automático y el Experto humano.

En otra prueba para comprobar la robustez del subsistema de clasificación, se inhibió el sistema de segmentación basado en conocimiento dejando que el segmentador realizara una segmentación por cada nivel de gris desde 1 a 254 y para cada una de las 36 imágenes citadas. De esta forma se generaron 249.992 regiones que, al ser clasificadas, no produjeron más error que el giro frío no detectado que aparece en la tabla.



Figura 6. Estructuras de interés superpuestas a la imagen AVHRR original.

Todas las figuras precedidas de asterisco se incluyen en el cuadernillo anexo de color

BIBLIOGRAFIA

- ARÍSTEGUI, J., SANGRÁ, P., HERNÁNDEZ-LEÓN S., CANTÓN, M., HERNÁNDEZ-GUERRA, A. y KERLING, J. L. 1994. Island-induced eddies in the Canary Islands. *Deep-Sea Res. Part I* 41 (10): 1509-1525. BEUCHER S. 1990. Segmentation Tools in Mathematical Morphology. *SPIE-1350 Image Algebra and Morphological Image Processing* 70-84.
- CANNY, J. 1983. Finding Edges and Lines in Images, Massachusetts Institute of Technology.
- GUINDOS, F., TORRES, J. A., PERALTA, M. y CANTÓN, M. 2001. Segmentación iterativa basada en conocimiento del afloramiento de aguas frías en la costa sahariana, *Teledetección, Medio Ambiente y Cambio Global*, 591-594.
- INTAN, R. y MUKAIDONO, M. 2002. Approximate reasoning in knowledge-based fuzzy sets, *Fuzzy Information Processing Society, Proceedings. NAFIPS. 2002 Annual Meeting of the North American* 439-444.
- THONET, H., LEMONNIER, B. y DELMAS, R. 1995. Automatic segmentation of oceanic eddies on AVHRR thermal infrared sea surface images, *Challenges of Our Changing Global Env. Conference Proceedings, OCEANS '95*, vol. 2, 1122-1127.
- TORRES, J. A., GUINDOS, F., PERALTA, M. y CANTÓN, M. 2003a. An Automatic Cloud-Masking System Using Backpro Neural Nets for AVHRR Scenes, *IEEE Transactions On Geoscience and Remote Sensing* 41 (4): 826-831.
- TORRES, J. A., GUINDOS, F., PERALTA, M. y CANTÓN, M. 2003b. Competitive neural-net based system for the automatic detection of oceanic mesoscalar structures on AVHRR scenes, *IEEE Transactions On Geoscience and Remote Sensing* 41 (4): 845-852.