

Interpretación automática de imágenes oceánicas mediante sistemas neurodifusos

J. A. Piedra, F. Guindos y M. Cantón
jpiedra@ual.es, fguindos@ual.es, mcanton@ual.es

Universidad de Almería. Escuela Politécnica Superior. Dpto. de Lenguajes y Computación

RESUMEN

El objetivo principal de este trabajo es mejorar la interpretación automática de las imágenes de satélite oceánicas. Se presenta un estudio comparativo sobre diferentes clasificadores: redes bayesianas, redes neuronales – función de base radial y sistemas difusos, sistemas neurodifusos y modelos de neurocomputación basados en retículos difusos.

PALABRAS CLAVE: clasificadores híbridos, redes bayesianas, sistemas neurodifusos.

ABSTRACT

The main goal of this work is to improve the automatic interpretation of ocean satellite images. We present a comparative study of different classifiers: bayesian network, artificial neural network – radial base function & fuzzy system, neurofuzzy system and fuzzy lattice neurocomputing model.

KEY WORDS: hybrid classifiers, bayesian networks, neurofuzzy systems.

INTRODUCCIÓN

Este trabajo se centra en el estudio de métodos de interpretación de imágenes de satélite para el reconocimiento de estructuras oceánicas mesoescalares. La dificultad del análisis de estas imágenes se debe principalmente a su variabilidad morfológica y contextual, así como a las condiciones meteorológicas, entre otros factores.

Este trabajo muestra los resultados obtenidos por un sistema de interpretación automática para imágenes del sensor AVHRR (Advanced Very High Resolution Radiometer), desarrollados para detectar y etiquetar estructuras oceánicas. Este sistema de interpretación automática contiene principalmente un conjunto formado por diversos clasificadores que permiten analizar y comparar los modelos de clasificación. Estos clasificadores se basan en los principios funcionales y operacionales derivados de las redes neuronales, los sistemas difusos y las redes bayesianas.

La zona de estudio se encuentra entre el noroeste de África y el Archipiélago Canario. Una descripción detallada de dicha zona se puede encontrar en García-Weil *et al.* (2000) y Tejera (1997). La principal característica de esta zona es la presencia de estructuras oceánicas mesoescalares tales como los afloramientos, las estelas y los giros cálidos y fríos.

ETAPAS DEL RECONOCIMIENTO AUTOMÁTICO

En la Figura 1 se muestra el proceso completo estructurado en bloques de las etapas fundamentales del reconocimiento automático. Se parte de una base de datos de imágenes AVHRR de la zona de estudio. Estas imágenes son preprocesadas, analizadas y segmentadas por un sistema experto gráfico (Guindos *et al.*, 2004).

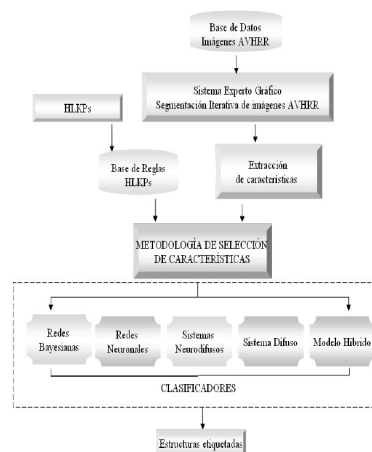


Figura 1. Etapas fundamentales para el reconocimiento de estructuras oceánicas.

La principal característica de dicho sistema es la presencia de una segmentación iterativa que permite ajustar de manera automatizada la segmentación óptima a partir de un conocimiento dado. Una vez segmentadas las imágenes la siguiente etapa se encarga de la extracción de características.

Además de las características numéricas calculadas utilizamos, el conocimiento extraído en forma de reglas de los HLKP –High-Level Knowledge Processor– (Torres *et al.*, 2003). Brevemente podemos decir que es un clasificador basado en redes neuronales que utiliza el conocimiento simbólico para la construcción de reglas, las cuales nos permiten aportar mayor conocimiento a la etapa de selección de características.

La metodología de selección de características permite utilizar las redes bayesianas para la reducción de características irrelevantes (Inza *et al.*, 2000). La metodología propuesta en (Piedra *et al.*, 2005) pretende obtener una aproximación de las características más relevantes mediante la utilización de las redes bayesianas y las técnicas de tipo filtro.

Una vez seleccionadas las características relevantes la siguiente etapa es la clasificación. En esta etapa se construyen diversos clasificadores: redes bayesianas, redes neuronales, sistemas híbridos – red neuronal de función de base radial y un sistema difuso tipo Sugeno –, sistemas neurodifusos – NEFPROX, NEFCLASS y ANFIS – y modelos neuronales basados en retículos difusos. La evaluación del comportamiento de todos estos clasificadores ha permitido conocer la eficiencia y comprensibilidad de los mismos.

CLASIFICADORES

El artículo se centra en el estudio del análisis del comportamiento clasificatorio de los sistemas neurodifusos en el reconocimiento de estructuras oceánicas. Para ello, se han seleccionado diferentes modelos neurodifusos por considerarlos pieza clave en este estudio –NEFCLASS–, por estructura peculiar basada en cinco capas sobre un sistema difuso –ANFIS–, por la mayor velocidad de computo y su capacidad de aprendizaje interpretable –NEFPROX– y por la capacidad de generalización y abstracción de reglas mediante la utilización de retículos difusos –s-FLNMAP–. Destacar que todos estos modelos obtienen buenos resultados en la literatura pero no han sido aplicados directamente al reconocimiento de estructuras oceánicas.

Sistema híbrido

El modelo cooperativo seleccionado está basado en un sistema híbrido formado por una red neuronal función de base radial –RBF– y en un sistema difuso de tipo Sugeno. En la fase de entrenamiento de este modelo la red neuronal RBF se usa para extraer el conjunto de reglas difusas que determinarán el funcionamiento del sistema difuso.

La posibilidad de generación de forma automática de Sugeno de orden cero a partir de una red neuronal RBF, se ha utilizado como base para la creación de un sistema difuso equivalente.

Este tipo de modelo ha sido utilizado por (Fernández y Corchado, 2004) en la predicción de las mareas rojas mediante sistemas neuro-simbólicos. Estos sistemas se basan en la metodología del razonamiento basado en casos. Las fases de recuperación y adaptación de casos se realizan mediante las redes neuronales RBF que permiten la creación de un modelo generado de forma automática a partir de los propios datos, que es capaz de adaptarse a los cambios continuos de las variables de entrada y aprender en función del error cometido en situaciones anteriores. Para la fase de revisión utiliza el sistema difuso tipo Sugeno, estableciendo una posible clasificación en función de la estructura de las reglas difusas empleadas por cada modelo.

Sistemas neurodifusos

Los sistemas neurodifusos permiten combinar las ventajas de las redes neuronales y de los sistemas difusos:

- Permite manejar información imprecisa, vaga o imperfecta.
- Utiliza cualquier tipo de información - numérica, lingüística, lógica, etc.
- Posee la capacidad de aprendizaje, organización y ajuste por sí mismo.
- No necesita conocimiento a priori sobre los datos.
- Reduce el proceso de toma de decisiones.

Uno de los sistemas seleccionados ANFIS –Adaptative Network Based Fuzzy Inference System– (Jang, 1993), es un sistema de inferencia difuso implementado sobre una red adaptativa. ANFIS puede servir como base para la construcción de un conjunto de reglas difusas con las funciones de pertenencia asociadas para generar parejas estipuladas de entrada-salida.

Por otra parte, usamos un modelo general para la aproximación de funciones mediante un modelo neurodifuso basado en aprendizaje supervisado. El modelo es NEFPROX –NeuroFuzzyfunction apPROXimator– (Nauck y Kruse, 1998), que tiene la capacidad de no necesitar aprendizaje reforzado. Además, este modelo deriva de NEFCLASS (Nauck *et al.*, 1996) (Nauck, 2000), pero la diferencia es que NEFCLASS sólo se utiliza en tareas de clasificación discreta.

Sistema neurocomputacional basado en retículos difusos

La neurocomputación de retículos difusos (Kaburlasos y Petridis, 2000) emerge como un paradigma conexionista sobre los retículos difusos, el cual tiene las ventajas de la capacidad de tratamiento con diferentes tipos de datos numéricos y lingüísticos, intervalos de valores, datos perdidos o imperfectos.

Clasificador	C	R	Aciertos
Sistema Híbrido	14	100	69,13
NEFCLASS	16	367	96,49
NEFPROX	16	420	89,62
ANFIS	14	407	83,63
σ -FLNMAP	15	156	92,29
Naïve Bayes	16	--	89,68
TAN	14	--	87,08

Tabla 1. Resultados comparativos de clasificación (en la primera fila la letra C = número de características y R= número de reglas utilizadas).

El clasificador σ -FLNMAP –Fuzzy Lattice Neural MAP– ha sido introducido en (Petridis y Kaburlasos, 2000). σ -FLNMAP es una sinergia de dos esquemas de agrupamiento σ -FLN. Los dos esquemas σ -FLN son denotados por σ -FLNa y σ -FLNb. En particular, σ -FLNa agrupa los datos de entrada, σ -FLNb agrupa los datos correspondientes a las categorías, donde un mapa de interconexiones permite asociar ambos esquemas. El mapa asigna una categoría a los grupos de datos de entrada. Las reglas extraídas por el clasificador σ -FLNMAP son representadas como hiperrectángulos.

Al final del proceso de aprendizaje, hay M hiperrectángulos particionados en K clases, donde K es la cardinalidad del conjunto finito de categorías. Una vez completado el proceso de aprendizaje, el

conjunto de hiperrectángulos calculados puede ser implementado como un árbol de decisión o una red neuronal.

Redes bayesianas

Las redes bayesianas han sido satisfactoriamente usadas como modelos para la representación de incertidumbre en las bases de datos de conocimiento. La incertidumbre es representada en términos de una distribución de probabilidad donde las relaciones de independencia inducidas son representadas por la estructura de la red.

Las redes bayesianas proveen una visualización gráfica intuitiva del conocimiento. En este trabajo hemos evaluado los dos clasificadores más simples y con mejores resultados en los procesos de clasificación:

- Naïve-Bayes (Duda y Hart, 2001): este método asume que todas las características son condicionalmente independientes cuando la clase es conocida. Esto implica que la estructura de la red es la más simple, ya que los únicos arcos en el grafo dirigido son los que relacionan la variable clase con cada una de las características. La ventaja es que tiene que aprender un menor número de parámetros que existen en las relaciones de independencia, ya que son las más simples y esto condiciona una menor tasa de error.
- Tree Augmented Naïve Bayes – TAN (Friedman *et al.*, 1997): es similar al modelo anterior con la salvedad de que las características pueden tener dos arcos dirigidos, uno de ellos de la clase y la clase no puede tener ningún arco dirigido que le llegue.

RESULTADOS

Los resultados obtenidos en el proceso de clasificación se muestran en la Tabla 1 para los modelos introducidos. Hay que destacar que se ha contado con un número de 1000 casos para las diferentes estructuras oceánicas. Estos casos han sido extraídos del conjunto de imágenes analizadas en el proceso de segmentación iterativa (Guindos *et al.*, 2004). La principal característica de estos casos es que pertenecen a diferentes aproximaciones de segmentaciones sobre una misma estructura. La tasa de aciertos de los clasificadores se ha realizado mediante validación cruzada.

Las mejores clasificaciones se obtienen para NEFCLASS y σ -FLNMAP. Es importante enfatizar el trabajo de los sistemas neurodifusos, ya que obtienen una buena tasa de aciertos y facilitan la adquisición de conocimiento a través de las reglas difusas muy cercanas a la comprensión humana.




Figura 2. Las estructuras reconocidas son el afloramiento, las estelas: La Palma, La Gomera, Tenerife, Gran Canaria y un giro frío.

La principal diferencia entre σ -FLNMAP y NEFCLASS radica en el número de reglas obtenidas, 156 y 367 respectivamente. Esto implica que se podría asumir la tasa de aciertos del 92.29% para σ -FLNMAP –que es 4.2% inferior a la obtenida por NEFCLASS– permitiendo un sistema mucho más comprensible ya que el número de reglas difusas es de un 58% inferior.

En la Figura 2 se muestra un ejemplo del resultado del reconocimiento de estructuras oceánicas.

CONCLUSIONES

Se han construido diversos clasificadores neurodifusos para analizar su comportamiento en nuestro dominio de estudio. Se ha observado que es difícil de cuantificar cuál es el mejor de los clasificadores neurodifusos desde el punto de vista de la comprensibilidad, ya que un incremento en las tasas de acierto conlleva a mermar la interpretabilidad de los

clasificadores. Uno de los sistemas neurodifusos novedosos expuestos ha sido σ -FLNMAP que utiliza tanto redes neuronales como retículos difusos. Éste ha permitido extraer los aspectos más generales en forma de reglas con valores de intervalos numéricos para cada una de las características que intervienen en el sistema.

Se ha realizado un estudio para aproximar cuál es el mejor clasificador. El criterio es la búsqueda del equilibrio entre el rendimiento (tasa de aciertos) y la comprensibilidad del usuario (cómo de cercano y simple le resulta la interpretación del sistema a un ser humano). Se ha observado por tanto que los sistemas neurodifusos en nuestro problema de estudio funcionan bastante bien y su representación es fácilmente interpretable.

AGRADECIMIENTOS

Este trabajo ha estado apoyado por el proyecto CICyT N° T/N2004-05346.

BIBLIOGRAFÍA

- DUDA R.O. y HART P. E. 2001. *Pattern classification*. John Wiley and Sons, New York.
- FERNÁNDEZ F. y CORCHADO J. M. 2004. *Forecasting System for Red Tides*. *Applied Intelligence*. 21 (3): 251-264.
- FRIEDMAN, N., GEIGER, D. Y GOLDSZMIDT M. 1997. Bayesian network classifiers. *Machine Learning* 29 (2): 131-164.
- GARCÍA-WEIL, L., PACHECO, M., RODRÍGUEZ, G. y T. McCLIMANS. 2000. *Topographic Effects on the Mesoscale Ocean Circulation near Canary Archipelago Examined by means of Satellite Images and Laboratory Simulations*. IEEE Int. Geoscience and Remote Sensing Symposium, Proc. IGARSS2000, páginas 1830-1832, Hawaii USA.
- GUINDOS F., PIEDRA J. A. Y CANTÓN M. 2004. *Ocean features recognition in AVHRR images by means of bayesian net and expert system*. 3rd International Workshop on Pattern Recognition in Remote Sensing, Kingston University, United Kingdom, August 2004.
- INZA, I., LARRAÑAGA, P., ETXEBERRIA R. y SIERRA B.. 2000. Feature subset selection by bayesian networks based optimization. *Artificial Intelligence* 123 (1-2): 157-184.

J. A. Piedra, F. Guindos y M. Cantón

- JANG, R. 1993. *ANFIS Adaptive Network based Fuzzy Inference System*. IEEE Transactions On Systems, Man and Cybernetics, vol. 23, número 3.
- KABURLASOS, V. G. y PETRIDIS, V. 2000. Fuzzy lattice neurocomputing (FLN) models. *Neural Networks* 13 (10): 1145-1170.
- NAUCK, D. y KRUSE, R. 1998. *A neuro-fuzzy approach to obtain interpretable fuzzy systems for function approximation*. Fuzzy Systems Proceedings, IEEE World Congress on Computational Intelligence, vol. 2, pp 1106–1111.
- NAUCK, D., NAUCK, U. y KRUSE, R. 1996. *Generating classification rules with the neuro-fuzzy system NEFCLASS*. Fuzzy Information Processing Society, NAFIPS, Biennial Conference of the North American, pp 466–470.
- NAUCK, D. 2000. *Knowledge discovery with NEFCLASS*. Fourth International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies, vol. 1, pp. 158-161.
- PETRIDIS, V. y KABURLASOS, V. G. 2000. Learning in the framework of fuzzy lattices. *IEEE Transactions on Fuzzy Systems* 7 (4): 422-440. Errata in IEEE Transactions on Fuzzy Systems 8 (2): 236.
- PIEDRA J. A., SALMERÓN A., CANTÓN M., GUINDOS F. y RUIZ D. 2005. *Reduction of irrelevant features in ocean satellite images by means of bayesian networks*. VI Jornadas de transferencia tecnológica de inteligencia artificial. I Congreso Español de Informática, pp. 133-140.
- TEJERA A. 1997. *Mesoscale variability in the canary region from altimetry*. In Proc 3rd ERS Symposium On Space at the service of our environment, volume 3, páginas 1509-1519, Florence, Italy ESA SP-414.
- TORRES J. A., GUINDOS F., LÓPEZ M. y CANTÓN M. 2003. *Competitive neural-net-based system for the automatic detection of oceanic mesoscalar structures on AVHRR scenes*. *IEEE Trans. on Geoscience and Remote Sensing* 41 (4): 845-852.