

Sistema Multiagente para la Evaluación y Predicción del Intercambio de CO₂ en el Océano Atlántico Norte

Israel García¹, Alberto Pastor¹, Javier Bajo², Vidal Alonso² y Juan Manuel Corchado¹

¹ Departamento Informática y Automática, Universidad de Salamanca
Plaza de la Merced s/n, 37008, Salamanca, Spain
tahonis21@gmail.com, alberto.es@gmail.com, corchado@usal.es

² Universidad Pontificia de Salamanca
Compañía 5, 37002, Salamanca, Spain
{jbajope, valonsose}@upsa.es

Abstract. En este artículo se presenta un sistema multiagente desarrollado para modelar la interacción existente entre la superficie del océano y la atmósfera. El corazón del sistema es un agente inteligente capaz de realizar predicciones sobre la absorción o expulsión de CO₂ en el océano Atlántico de forma autónoma. El sistema multiagente ha sido probado en condiciones de simulación, y en este trabajo se presentan los resultados preliminares obtenidos.

Keywords: Sistema multiagente; CBR-BDI; CO₂.

1. Introducción

Los sistemas multiagente (SMA) son aplicaciones informáticas distribuidas con autonomía y cierto grado de “inteligencia”, cuyos componentes son agentes. Un agente es una entidad que posee ciertas características, tales como autonomía, situación, reactividad, proactividad, habilidad social, aprendizaje, movilidad u organización [20]. La mayor parte de las arquitecturas actuales se basan en el modelo BDI [5]. Sin embargo, una de las principales carencias del modelo BDI se encuentra en que se carece de mecanismos eficientes de gestión de la memoria y de las experiencias pasadas. Una de las posibilidades para mejorar la eficiencia de la arquitectura BDI es la utilizar sistemas de razonamiento basado en casos (CBR) [1], como mecanismo de razonamiento. De esta forma se consiguen agentes CBR-BDI [6], con una gran capacidad de aprendizaje y de adaptación. Hoy en día es un hecho la creciente utilización de los agentes y sistemas multiagente para el desarrollo de aplicaciones en entornos dinámicos y flexibles tales como la Web, sistemas de control, robótica, etc. En este documento se presenta una arquitectura distribuida cuya principal característica es la utilización de agentes CBR-BDI [8] para la monitorización y la predicción del intercambio de CO₂ existente entre la atmósfera y la superficie de las aguas oceánicas, basado en la utilización de los datos obtenidos a través de técnicas de teledetección. Las características del problema de la interacción

mar-aire hacen que resulte muy adecuada la utilización de un SMA para la generación de modelos dinámicos de forma automática.

Se denomina agente CBR-BDI [6] a un agente deliberativo BDI que incorpora un sistema CBR como motor de razonamiento. Estos agentes son capaces de aprender, a partir de un conocimiento inicial, interactuar autónomamente con el entorno y con los usuarios del sistema y se adaptan a las necesidades del entorno. En el modelo BDI la estructura interna de un agente y su capacidad de elección se basan en aptitudes mentales. Esto tiene la ventaja de utilizar un modelo natural (humano) y de alto nivel de abstracción. El modelo BDI utiliza Beliefs (Creencias) como aptitudes informacionales, Desires (Deseos) como aptitudes motivacionales e Intentions (Intenciones) como aptitudes deliberativas de los agentes. El método propuesto en [6, 11] facilita la incorporación de sistemas CBR como mecanismo deliberativo en agentes BDI, proporcionando un aprendizaje, adaptación y un mayor grado de autonomía que una arquitectura BDI pura [5]. El CBR es un paradigma que se basa en la idea de que los problemas similares tienen soluciones similares. De esta forma, un problema nuevo se resuelve consultando en la memoria experiencias similares que se hubiesen resuelto en el pasado.

En la siguiente sección se presenta el problema oceánico/atmosférico que motiva la mayor parte de esta investigación. En la tercera sección se muestra el sistema multiagente desarrollado. En la sección 4 se analiza la estructura interna del agente CBR-BDI encargado de generar modelos y realizar predicciones. Finalmente se presentan unos resultados preliminares y las conclusiones obtenidas.

2. Problema de la Interacción Aire Mar

Uno de los factores más preocupantes que influyen en el comportamiento climatológico es la cantidad de CO₂ presente en la atmósfera. El CO₂ es uno de los gases de efecto invernadero, que contribuye a que la Tierra tenga una temperatura habitable, siempre y cuando se mantenga en unas cantidades determinadas [17]. Tradicionalmente se ha considerado que el principal sistema regulador de la cantidad de CO₂ en la atmósfera es la fotosíntesis y respiración realizado por las plantas. Sin embargo, y especialmente gracias a la utilización de técnicas de teledetección se ha descubierto que el papel que juega el océano en la regulación de las cantidades de carbono es muy importante y es una magnitud que permanece indefinida [18]. La tecnología actual permite obtener datos y realizar cálculos impensables hasta hace poco tiempo. Estos datos proporcionan conocimiento sobre las fuentes de origen y disminución de CO₂ así como de sus causas [14], lo que supone la posibilidad de realizar predicciones sobre el comportamiento futuro del CO₂.

El sistema multiagente que se presenta tiene como objetivo modelar el flujo de CO₂ intercambiado entre la atmósfera y las aguas de la superficie oceánica. Los principales parámetros a tener en cuenta a la hora de modelar el intercambio de CO₂ entre la atmósfera y la superficie oceánica son: la temperatura del agua y del aire, la salinidad del agua, las presiones atmosféricas e hidrostáticas, la presencia de nutrientes y el vector velocidad del viento (en módulo y dirección). Estos parámetros pueden obtenerse a través de mediciones in-situ realizadas desde barcos

oceanográficos o bien a través de imágenes de satélite. La información de satélite es vital para la construcción de modelos oceanográficos, y en este caso, para generar estimaciones de los flujos de CO₂ entre el aire y el mar con una alta resolución tanto espacial como temporal, utilizando modelos de inteligencia artificial que pueden ser contrastados con la realidad por medio de muestreos directos in situ sobre el CO₂ de la superficie del océano. Será necesario utilizar sistemas distribuidos automatizados y capaces de incorporar nuevo conocimiento para poder manejar todos los datos útiles y para crear modelos diarios en un tiempo y coste razonables. Nuestra propuesta se presenta en la siguiente sección.

3. Sistema Multiagente para la Interacción Aire-Mar

El objetivo final de este trabajo es construir un gran sistema multiagente organizado en subsistemas, de tal forma que cada subsistema se encargue de modelar el intercambio de CO₂ en una zona del océano con unas determinadas características. Cada subsistema se comunicará con el resto de los subsistemas, obteniendo un intercambio de información que ayude a la creación de modelos y que facilite las predicciones. Dado que se trata de un proyecto de gran magnitud, en este trabajo se presenta el estudio y desarrollo de un subsistema, cuya arquitectura final puede observarse en la **Figura 1**.

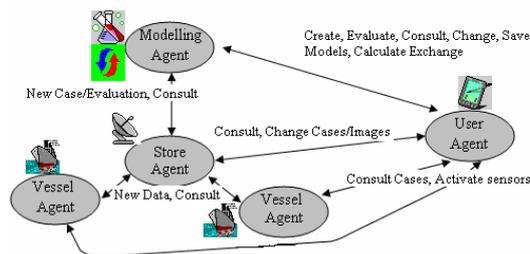


Fig. 1. SMA correspondiente a un subsistema para una zona concreta del Océano.

Por el momento se ha desarrollado el prototipo correspondiente a un subsistema como el mostrado en la **Figura 1**, en la que es posible observar como en un subsistema participan cuatro tipos diferentes de agentes: un tipo de agente Modelling, encargado de la creación y evaluación de modelos en función de los datos recibidos desde los agentes Store, Vessel o User, así como de la obtención de predicciones; un tipo de agente Store, encargado de almacenar los datos obtenidos a partir de imágenes de satélite; un tipo de agente Vessel, encargado de gestionar los datos obtenidos por medio de un barco oceanográfico; y un tipo agente User que permite a los oceanógrafos interactuar con el sistema multiagente.

Los modelos generados por el agente Modelling permiten predecir el intercambio de CO₂ entre la superficie del océano y la atmósfera. Para crear un nuevo modelo es necesario disponer de información proporcione una descripción inicial del problema a modelar. La descripción del problema se obtiene por medio de los datos obtenidos a través de imágenes de satélite. El agente Store se encarga de procesar las imágenes de

satélite y transformarlas para que el sistema pueda utilizarlas. En la **Figura 2** es posible apreciar una captura de pantalla correspondiente al agente Store. En ella se muestran los datos obtenidos por medio de imágenes de satélite en un rango de fechas, para un determinado intervalo de latitudes y longitudes. Los datos que se obtienen a partir del procesamiento de imágenes de satélite son principalmente datos de clorofila, salinidad y temperatura. Para transformar las imágenes de satélite el agente Store utiliza algoritmos [9, 13]. La **Figura 2** muestra los datos ya procesados obtenidos para zonas concretas del Atlántico Norte. Los datos obtenidos son enviados al agente Modelling para que pueda crear nuevos modelos. Estos modelos tienen que ser evaluados para comprobar su bondad. Para ello se utiliza la información obtenida por medio de cada agente Vessel que se instala en un navío y recoge datos in-situ que pueden permitir contrastar los resultados obtenidos por medio de los modelos creados por el agente Modelling. El agente usuario puede interactuar con cualquier agente del sistema y puede ser ejecutado sobre dispositivos móviles, tales como PDAs, lo cual facilita enormemente el trabajo de los oceanógrafos, permitiendo una gran libertad de movimientos e independencia de la localización. Cada oceanógrafo dispone de un agente de usuario situado en un dispositivo ligero que le permite acceder al SMA de forma inalámbrica.

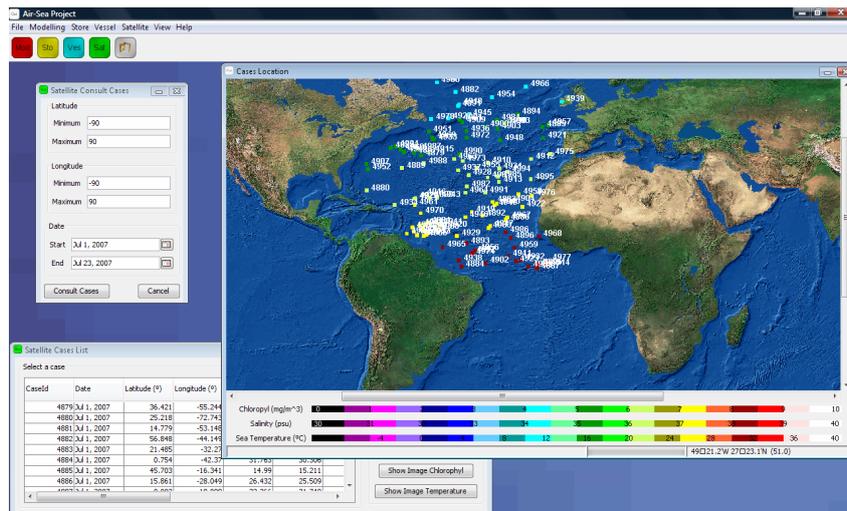


Fig. 2. Agente Store. Casos obtenidos a partir de imágenes de satélite.

La implementación del sistema se ha realizado utilizando la plataforma Jade [4] y la herramienta Jadex [16], que es una extensión que permite dotar de una arquitectura BDI a los agentes Jade. De esta forma los agentes Jadex trabajan con conceptos de beliefs (creencias), goals (metas) y plans (planes). Jadex tiene la ventaja de permitir que el programador pueda introducir sus propios mecanismos deliberativos. En nuestro caso este mecanismo va a ser un sistema CBR. El agente Modelling es un agente Jadex, mientras que el resto de agentes se construyen con Jade. Además, una de las ventajas de utilizar Jadex radica en que es posible utilizar los mecanismos de comunicación utilizados por Jade [4, 16].

4. Agente para la Creación de Modelos Oceanográficos

El componente principal de la arquitectura propuesta es el agente Modelling, encargado de generar modelos y realizar predicciones. Se trata de un agente deliberativo BDI [20] que utiliza un sistema CBR como motor de razonamiento. Un sistema CBR maneja casos. Un caso es una experiencia pasada, que incluye una descripción del problema, la solución utilizada para resolverlo y el resultado obtenido. Construir un agente CBR-BDI [6, 11] supone por un lado integrar el concepto de caso en la estructura del modelo BDI y por otro lado que el agente BDI ejecute el ciclo CBR. De esta forma la generación de un modelo supone la ejecución de un ciclo de razonamiento CBR formado por cuatro etapas secuenciales: retrieval, reuse, revise y retain. La etapa retrieval consiste en recuperar de la memoria de casos aquellos casos que posean una descripción de problema similar al problema actual. La etapa reuse consiste en adaptar las soluciones correspondientes a las descripciones de problema similares recuperadas para crear una nueva solución. En la etapa revise se evalúa la solución proporcionada. Por último, en la etapa retain, se aprende de la nueva experiencia. Tal y como se puede apreciar en la **Figura 3**, el agente CBR-BDI utiliza sus estructuras internas para representar un caso: creencias, deseos e intenciones. Creencias para representar la descripción del problema, una creencia de tipo ProblemDescription (obteniendo una descripción de problema como la mostrada en la Tabla 1: fecha, latitud, longitud, salinidad, clorofila, viento, presiones parciales y temperaturas). Deseos para representar las metas que el agente persigue (predecir el flujo de CO₂ intercambiado, calcular los mejores parámetros de predicción para distintos tamaños de ventana, y calcular la mejor ventana de predicción para un determinado % de error máximo permitido). Intenciones o secuencias de acciones para alcanzar una o varias metas en función de las creencias de las que se dispone.

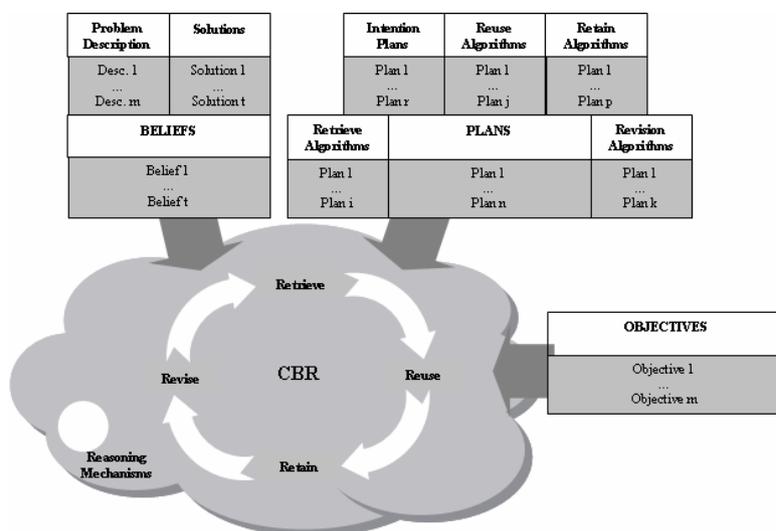


Fig. 3. Estructura interna de un agente CBR-BDI.

Table 1. Atributos de los casos.

Atributo del Caso	Valor
DATE	Fecha (dd/mm/yyyy)
LAT	Latitud (grados decimales)
LONG	Longitud (grados decimales)
SST	Temperatura (°C)
S	Salinidad (sin unidades)
WS	Fuerza del viento (m/s)
WD	Dirección del viento (sin unidades)
Fluo_calibrated	Fluorescencia calibrada con clofófila
SW pCO ₂	Presión parcial de CO ₂ en la superficie marina (micro Atmósferas)
Air pCO ₂	Presión parcial de CO ₂ en el aire (micro Atmósferas)
Flux of CO ₂	Flujo de CO ₂ intercambiado (Moles/m ²)

La forma de implantar el ciclo CBR dentro de un agente BDI consiste en que el agente BDI ejecute las etapas del ciclo CBR como capacidades [2]. Un agente BDI posee capacidades (funcionalidades que el agente es capaz de realizar por sí mismo sin necesidad de contactar con otros agentes) y ofrece servicios a otros agentes. Como se puede observar en la Figura 4, el agente Modelling ofrece cuatro servicios (Obtain Exchange, Obtain Model, Obtain Evaluation y Construct Model) y posee seis capacidades (Forecast Exchange Rate, Evaluate Model, Consult Model, Jacobean Sensivity Matriz - JSM, Pondered Weigh Technique - PWT y Revision Simulated Equation - RSE).

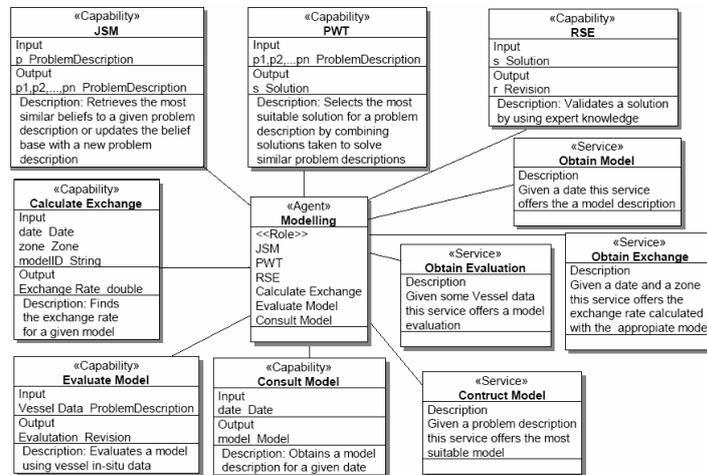


Fig. 4. Diagrama de clases para el agente Modelling.

Las tres últimas capacidades constituyen el ciclo CBR, y su funcionamiento cuando se recibe una nueva descripción de problema es el que a continuación pasa a describirse: En la etapa de recuperación la capacidad JSM permite obtener aquellos casos con una descripción de problema más similar a la del caso actual [15]. Para ello se utiliza una red neuronal que permite obtener las componentes principales de la memoria de casos, y conocer cuales de las variables de entrada (que forman la

descripción del problema) tienen mayor influencia a la hora de crear clusters. Si consideramos JSM una matriz $N \times M$, el elemento S_{ki} en la matriz representa la sensibilidad (influencia) de la salida k sobre la entrada i , como muestra la ecuación 1.

$$S_{ki} = \frac{\partial y_k}{\partial x_i} = \frac{\partial f_k(net_k)}{\partial x_i} = \frac{\partial f_k(net_k)}{\partial net_k} \frac{\partial net_k}{\partial y_j} \frac{\partial y_j}{\partial net_j} \frac{\partial net_j}{\partial x_i} = \frac{\partial f_k(net_k)}{\partial net_k} \left(\sum_{j=1}^H w_{kj} \frac{\partial f_j(net_j)}{\partial net_j} w_{ji} \right) \quad (1)$$

Donde w_{ij} es el peso de la conexión entre la neurona de entrada i y la neurona oculta j . w_{kj} es el peso de la conexión entre la neurona oculta j y la neurona de salida k . y_k es la salida de la neurona k de la capa de salida $y_k = f_k(net_k)$, y y_j es la salida de la neurona j de la capa oculta $y_j = f_j(net_j)$. f_j es la función de activación de la neurona h y net_j , net_k se obtienen a partir de las ecuaciones 2 y 3 respectivamente. Siendo H el número de neuronas de la capa oculta, y θ_j y θ_k los umbrales permitidos. Una vez obtenidas las componentes principales se busca en la memoria de casos aquellos con componentes principales más similares a la descripción del problema actual. Para ello se utiliza un algoritmo de similitud basado en la función coseno.

$$net_j = \sum_{i=1}^N w_{ji} x_i + \theta_j \quad (2)$$

$$net_k = \sum_{j=1}^H w_{kj} y_j + \theta_k \quad (3)$$

En la etapa de adaptación se combinan las soluciones de los casos similares recuperados para obtener una solución adecuada al problema actual. Se efectúa mediante la capacidad PWT, en la que los casos se ponderan [10] y se asigna el mayor peso al caso con una descripción de problema más similar a la del caso actual.

$$p^* = \frac{1}{\sum_{r=1}^Z e^{-|a-r|}} \sum_{r=1}^Z e^{-|a-r|} p^r \quad (4)$$

La ecuación 4 muestra el proceso de adaptación, donde p^* es la predicción, Z el número de casos similares y p^r son las predicciones (soluciones) correspondientes a cada caso pasado, a es la medida de mínima similitud para los casos recuperados y r es la medida de similitud para el caso r -ésimo. Se utiliza una red neuronal que se entrena con los casos similares recuperados y sus respectivas soluciones. Una vez entrenada se le proporciona el caso actual y se obtiene su solución.

En la etapa de revisión cada modelo se revisa en la capacidad RSE. Para ello se utiliza la ecuación 5 con los coeficientes de intercambio de Wanninkhof [19].

$$F = kso(pCO_2SW - pCO_2AIR) \quad (5)$$

Finalmente, en la etapa de aprendizaje se compara el valor F con el valor de la predicción. Si la diferencia es inferior al 10%, el caso se almacena en la base de creencias. La etapa de aprendizaje también se efectúa en la capacidad RSE. En este caso se ha considerado que el aprendizaje resulta más eficiente si se tienen en cuenta las experiencias positivas, desechado las negativas. La razón está en la gran cantidad de datos disponibles.

5. Resultados y Conclusiones

El sistema descrito ha sido probado con datos recogidos en el Océano Atlántico Norte durante 2004. A pesar de que el sistema no se encuentra totalmente operativo y que el objetivo del proyecto es el de construir un prototipo para investigación y no una herramienta comercial, los resultados iniciales han sido muy satisfactorios desde los puntos de vista técnico y científico. La construcción del sistema distribuido ha sido relativamente fácil gracias a la utilización de bibliotecas CBR-BDI previamente desarrolladas [2, 3, 6, 7]. El formalismo definido en [11] facilita un paso directo entre la definición de agente y la construcción CBR. La utilización de dispositivos inalámbricos ha sido valorada positivamente por los oceanógrafos, indicando que proporciona una gran movilidad y facilidad de acceso al sistema. Los interfaces se han adaptado para poder ser ejecutados tanto en ordenadores personales como en dispositivos móviles, caracterizados por su limitación en las capacidades de almacenamiento y procesamiento. La Figura 5 muestra dos capturas de pantalla correspondientes al interfaz de un agente Vessel. En la imagen de la izquierda es posible apreciar la misión realizada por el barco y los datos obtenidos. En la imagen de la derecha se muestra la ruta seguida por el barco, utilizando la herramienta Google Earth [12], que ha sido integrada con el sistema.

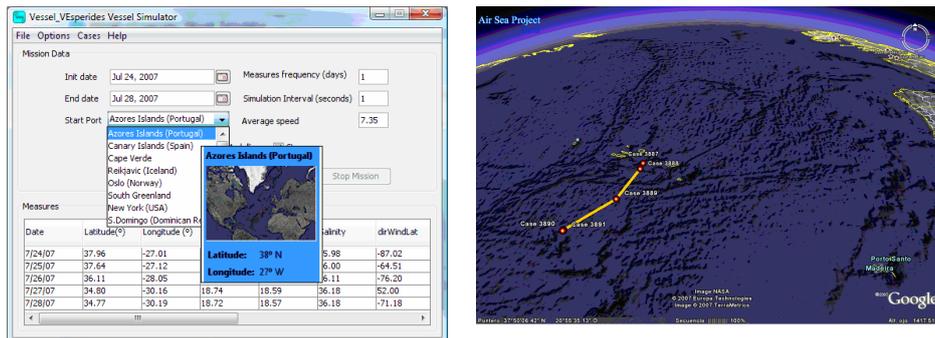


Fig. 5. Utilización de la herramienta Google

La Figura 6 muestra el interfaz correspondiente a un agente Modelling, concretamente para la generación de un modelo. En la Figura 6 es posible observar cómo un oceanógrafo puede configurar manualmente cada uno de los algoritmos utilizados en cada etapa del ciclo CBR. La interacción con el SMA por parte de desarrolladores y oceanógrafos ha sido continua durante su construcción y periodo de prueba. El sistema ha sido probado bajo condiciones de simulación de tal forma que los agentes Store y Vessel se han construido incluyendo simuladores que generan casos a partir de los datos reales obtenidos en el Océano Atlántico ($\pm 37^{\circ}\text{N}$, 25°W). Bajo estas condiciones los modelos propuestos por el sistema multiagente han sido cada vez más precisos. Sin embargo, si el número de casos manejado es muy elevado la eficiencia del sistema disminuye. La Figura 7 muestra una comparativa entre los datos reales y las predicciones realizadas por el SMA trabajando con datos relativos a meses de 2003-2004.

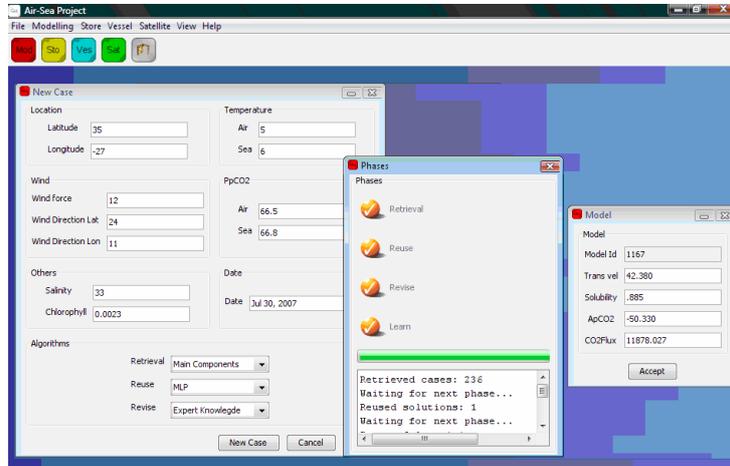


Fig. 6. Captura de pantalla de un agente Modelling correspondiente a la creación de un modelo.

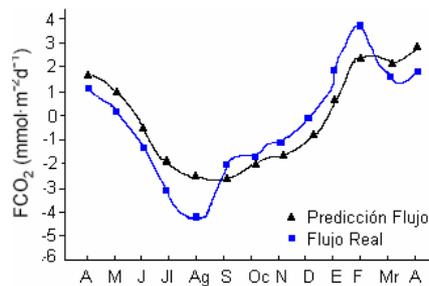


Fig. 7. Flujo real de CO₂ y predicción de flujo.

Como puede observarse en la **Figura 7** las predicciones realizadas por el SMA son bastante precisas (9 de los 12 modelos fueron aceptados como válidos). El SMA realiza predicciones basándose en su experiencia y en la similitud con situaciones pasadas. Claramente la precisión de las predicciones mejora a medida que el número de casos disponibles aumenta. Por otro lado es necesario controlar que el número de casos manejado no sea excesivo. Para ello se ha utilizado un sistema de prioridades basado en crear una estructura piramidal de eficiencias que permite clasificar los casos en base a la eficiencia obtenida. El sistema facilita la incorporación de nuevos agentes que utilicen diferentes técnicas de modelado y estrategias de aprendizaje de forma que se puedan realizar experimentos adicionales con nuevas técnicas y puedan ser comparados con los resultados iniciales presentados en este documento.

Agradecimientos. Este trabajo se ha llevado a cabo gracias a los proyectos MCYT TIC2003-07369-CO2-02 y CAXIS de PML.

Referencias

1. Aamodt A. and Plaza E.: Case-Based Reasoning: foundational Issues, Methodological Variations, and System Approaches, AICOM. Vol. 7., pp 39-59 (1994)
2. Bajo J. and Corchado J.M (2005). Evaluation and monitoring of the air-sea interaction using a CBR-Agents approach. LNAI 3620, pp. 50-62. Springer Verlag
3. Bajo J. and Corchado J.M. (2006). Multiagent architecture for monitoring the North-Atlantic carbon dioxide Exchange rate. CAEPIA 2005. LNCS 4177, pp 321-330
4. Bellifime, F. Poggi, A. and Rimasa, G. (2001) JADE: a FIPA2000 compliant agent development environment. Agents 2001 pp. 216-217.
5. Bratman, M.E. (1987). Intentions, Plans and Practical Reason. Harvard University Press, Cambridge, M.A.
6. Corchado J. M. and Laza R. (2003). Constructing Deliberative Agents with Case-based Reasoning Technology, International Journal of Intelligent Systems. Vol 18, No. 12, December. pp.: 1227-1241
7. Corchado J.M., Bajo J., de Paz Y. y Tapia D. I.: Intelligent Environment for Monitoring Alzheimer Patients, Agent Technology for Health Care. Decision Support Systems. Eslevier Science. In Press (2007)
8. Corchado J.M., Glez-Bedia M., de Paz Y., Bajo J. y de Paz J.F. Concept, formulation and mechanism for agent replanification: MRP Architecture. Computational Intelligence. Blackwell Publishers. In Press (2008)
9. Dransfeld S., Tatnall A.R., Robinson I. S. and Mobley C.D. (2005). Prioritizing ocean colour channels by neural network input reflectance perturbation. International Journal of Remote Sensing, 26, (5), 043-1048.
10. De Paz Santana Y (2005) Mixture Weibull distribution using artificial neural networks with cnsurated data PHD thesis, chapter 3.
11. Glez-Bedia M., Corchado J. M., Corchado E. S. and Fyfe C. (2002) Analytical Model for Constructing Deliberative Agents, Engineering Intelligent Systems, Vol 3: pp. 173-185.
12. Google Earth (2007) www.google.com.
13. Lavencer S.J., Pinkerton M.H., Froidefond J.M., Morales J., Aiken J. and Moore J.F. (2004) SeaWiFS validation in European coastal waters using optical and bio-geochemical measurements. International Journal of Remote Sensing, Vol. 25, No. 7-8, pp. 1481-1488
14. Lefevre N., Aiken J., Rutllant J., Daneri G., Lavender S. and Smyth T. (2002) Observations of pCO₂ in the coastal upwelling off Chile: Sapatial and temporal extrapolation using satellite data. Journal of Geophysical research. Vol. 107, no. 0
15. Montaña Moreno J.J. and Palmer Pol A. (2002). Artificial Neural Networks, opening the black box. Metodología de las Ciencias del Comportamiento 4(1) 77-93.
16. Pokahr, A., Braubach, L. and Lamersdorf W. (2003) Jadex: Implementing a BDI-Infrastructure for JADE Agents, in: EXP - In Search of Innovation (Special Issue on JADE), Vol 3, Nr. 3, Telecom Italia Lab, Turin, Italy, September 2003, pp. 76-85.
17. Sarmiento J. L. and Dender M. (1994) Carbon biogeochemistry and climate change. Photosynthesis Research, Vol. 39, 209-234.
18. Takahashi T., Olafsson J., Goddard J. G., Chipman D. W. and Sutherland S. C. (1993) Seasonal Variation of CO₂ and nutrients in the High-latitude surface oceans: a comparative study. Global biochemical Cycles. Vol. 7, no. 4. pp 843-878.
19. Wanninkhof, R. (1992). Relationship between wind speed and gas exchange over the ocean. J. Geophys. Res. 97, 7, 373-7, 383.
20. Wooldridge M. and Jennings N.R. (1995) Agent Theories, Architectures, and Languages: a Survey. Wooldridge and Jennings, editors, Intelligent Agents, Springer-Verlag, pp. 1-22.