

Modelo para diseñar sistemas de enseñanza-aprendizaje inteligentes utilizando el razonamiento basado en casos

Model to design intelligent teaching-learning systems using the case-based reasoning

Natalia Martínez Sánchez. Dra, María Matilde García Lorenzo. Dra, y Zoila Zenaida García Valdivia. Dra,
Departamento de Ciencia de la Computación. Universidad Central de Las Villas, Cuba
{natalia, mmgarcia, zgarcia}@uclv.edu.cu

Recibido para revisión 02 de abril de 2009, aceptado 23 de Octubre de 2009, versión final 10 de Diciembre de 2009

Resumen—Los Sistemas de Enseñanza-Aprendizaje Inteligentes son programas que portan conocimientos de cierto contenido mediante un proceso interactivo individualizado con el estudiante. En este trabajo se expone un modelo que favorece la concepción y desarrollo de Sistemas de Enseñanza-Aprendizaje Inteligentes (SEAI) utilizando el paradigma del razonamiento basado en casos, teniendo en cuenta las facilidades y naturalidad del enfoque basado en casos para integrar las 3 componentes de un SEAI.

Se proponen algoritmos para organizar la base de casos, la selección de los casos más similares a partir de la propuesta de una función de semejanza y la adaptación del nuevo problema a partir de la decisión a tomar sobre la base los casos más similares recuperados. Se parte de la descripción de los casos adecuada al tipo de problema a resolver, donde un caso contiene el modelo del estudiante, su diagnóstico y la decisión de qué y cómo enseñar.

Palabras Clave—Razonamiento Basado en Casos, Sistemas de Enseñanza-Aprendizaje Inteligentes, Modelado del Estudiante, Sistemas Basados en el Conocimiento, Sistemas Tutoriales Inteligentes, Inteligencia Artificial.

Abstract—The Intelligent Teaching-Learning Systems are programs which carry knowledge about certain subject through an individualized interactive process.

In the present work, a model which integrates the case-based reasoning paradigm and the Intelligent Teaching-Learning Systems is proposed, the model favors the design of these systems, taking into account the facilities and naturalness of the case-based approach.

Some algorithms to organize the base of cases are proposed, also for the selection of the more similar cases starting from a similarity function and for the adaptation to the new problem based on the decision to take. These algorithms start from the description of the cases according to this kind of problem, where a case contains the student model, his diagnosis and the decision of what and how to teach.

Finally, the validation results of the proposed model are illustrated.

Keywords—Cases Based Reasoning, Student Modeling, Intelligent Teaching-Learning Systems, Knowledge Based Systems, Intelligent Tutorials Systems, Artificial intelligence.

I. INTRODUCCIÓN

Un Sistema de Enseñanza-Aprendizaje Inteligente (SEAI) lo componen tres módulos fundamentales. El Módulo del Estudiante que almacena la información relacionada con el alumno, a través de él se determina ¿Qué conoce el estudiante? y a partir de la respuesta a esta interrogante se infiere ¿Qué enseñar? y ¿Cómo enseñar?, informaciones representadas en el Módulo del Dominio y Módulo Pedagógico respectivamente siendo estos los otros dos módulos de los SEAI.

Los sistemas basados en el conocimiento [1], [2] constituyen paradigmas computacionales de la Inteligencia Artificial (IA) válidas para enfrentar la construcción de SEAI dado por sus aspectos afines. Estos sistemas utilizan conocimiento sobre un dominio específico. La solución que se obtiene es similar a la obtenida por una persona experimentada en el dominio del problema. Por su parte los SEAI utilizan la información almacenada sobre las características del estudiante para adaptar el proceso de enseñanza-aprendizaje del mismo a la materia a enseñar.

Una característica distintiva de los sistemas basados en el conocimiento es la separación del conocimiento (base de conocimiento) del método de solución del problema (máquina de inferencia). La construcción de la base del conocimiento lleva implícito un arduo proceso de adquisición del conocimiento y es particular para cada sistema, por lo que será necesario construirla para cada aplicación. Sin embargo, la máquina de inferencia puede reusarse en la construcción de varios sistemas basados en el conocimiento siempre que el tipo de conocimiento

y el tipo del razonamiento sea similar.

Diferentes tipos de conocimiento dan lugar a diferentes tipos de sistemas basados en el conocimiento, entre ellos los sistemas basados en reglas [3], [4], los sistemas basados en probabilidades [5], [6], sistemas expertos conexionistas o redes expertas [7], [8] y los sistemas basados en casos [9], [10] y [11].

No todos los paradigmas para crear sistemas basados en el conocimiento facilitan la concepción de un SEAI, donde lo fundamental para su desarrollo es determinar cómo representar el conocimiento requerido para sus módulos y a partir de dicho conocimiento realizar un diagnóstico del estudiante para que el sistema se adapte a sus características. Sin embargo, similitudes de los SEAI y los Sistemas Basados en Casos son factores a tener en cuenta para concebir todos los módulos de los SEAI y un diagnóstico adecuado del qué y cómo enseñar dependiendo del estudiante.

En particular resulta claro que el desarrollo de SEAI requiere, además de conocimiento en el dominio de aplicación, de conocimientos de programación e Inteligencia Artificial y ellos no siempre coexisten en los especialistas, lo que ha motivado que el desarrollo de tales sistemas hasta ahora haya sido posible sólo con un enfoque multidisciplinario.

Consecuentemente con lo expuesto anteriormente en este trabajo se presenta un modelo que integra el Razonamiento Basado en Casos y los SEAI para facilitar a profesores, no necesariamente expertos en el campo informático, el desarrollo de este tipo de Sistemas de Enseñanza-Aprendizaje en cualquier área del saber.

El artículo está conformado por cuatro epígrafes. Un primer epígrafe donde se realiza una caracterización de los SEAI y se analiza cómo el proceso del modelado del estudiante ha motivado la aplicación de técnicas de IA. A continuación un segundo epígrafe que describe el Razonamiento Basado en Casos como una alternativa para la elaboración de los SEAI, valorándose las ventajas de este.

En el tercer y cuarto epígrafe se abordan concretamente la definición del modelo propuesto para elaborar SEAI utilizando el Razonamiento Basado en Casos, así como los algoritmos que se utilizan de forma complementaria para facilitar la ingeniería del conocimiento en el modelado del estudiante. Y se hace un análisis de los resultados de la validación del modelo propuesto.

Por último, se establecen las Conclusiones y se relacionan las Referencias Bibliográficas.

II. MODELADO DEL ESTUDIANTE EN LOS SISTEMAS DE ENSEÑANZA-APRENDIZAJE INTELIGENTES

El modelado del alumno es un problema central en el diseño y desarrollo de los Sistemas de Enseñanza-Aprendizaje Inteligentes (SEAI). En efecto, si la característica que distingue

a los SEAI de los Sistemas de Enseñanza-Aprendizaje es su capacidad de adaptación al alumno; entonces un SEAI debe ser capaz de determinar con la mayor precisión y rapidez posible cuál es el estado cognitivo y afectivo-motivacional del estudiante; para poder personalizar el proceso de enseñanza-aprendizaje.

El problema del modelado del alumno está en seleccionar la estructura de datos para representar toda la información relativa al alumno y elegir el procedimiento que se utiliza para realizar el diagnóstico. Evidentemente ambas componentes están estrechamente relacionadas, y por tanto se diseñan y desarrollan simultáneamente.

Los Sistemas de Enseñanza-Aprendizaje Inteligentes son programas que portan conocimientos sobre cierta materia y cuyo propósito es transmitir este conocimiento a los alumnos mediante un proceso interactivo individualizado, intentando simular la forma en que un tutor o profesor guiaría al alumno en el proceso de enseñanza-aprendizaje [12], [13].

El término inteligente se refiere a la habilidad del sistema sobre qué enseñar, cuándo enseñar y cómo enseñar, simulando la actividad de un profesor real. Para lograrlo, un SEAI debe encontrar la información relevante sobre el proceso de aprendizaje de ese estudiante y aplicar el mejor medio de instrucción según sus necesidades individuales [14], [15].

La arquitectura básica de un SEAI descrita en [16] reúne los elementos más comúnmente encontrados en la literatura consultada y se resumen en el criterio que plantea que un SEAI está compuesto por un módulo del dominio, un módulo del alumno y el módulo pedagógico, que operan de forma interactiva y se comunican a través de un módulo central que suele denominarse módulo entorno.

El modelo del estudiante es un problema de investigación que debe enfocarse desde todas sus aristas con el fin de obtener una representación completa y precisa de las características del estudiante. Algunos autores toman en consideración características tales como: el estilo de aprendizaje [17], [18], el nivel de conocimiento [19], [20], la información personal [21], [22], o la combinación de algunas de ellas.

El módulo del dominio, denominado también por muchos autores como módulo experto, proporciona los conocimientos del dominio. Satisface dos propósitos diferentes. En primer lugar, presentar la materia de la forma adecuada para que el alumno adquiera las habilidades y conceptos, lo que incluye la capacidad de generar preguntas, explicaciones, respuestas y tareas para el alumno. En segundo lugar, el módulo del dominio debe ser capaz de resolver los problemas generados, corregir las soluciones presentadas y aceptar aquellas soluciones válidas que han sido obtenidas por medios distintos.

En este módulo, el conocimiento que debe enseñarse por el SEAI debe organizarse pedagógicamente para facilitar el proceso de enseñanza-aprendizaje [23], [24].

El módulo pedagógico decide qué, cómo y cuándo enseñar los contenidos del tutor, adaptando sus decisiones pedagógicas a las necesidades del estudiante [25]. Algunos autores le denominan módulo tutor, ya que es el encargado de comparar las características de los estudiantes con el contenido a enseñar y elegir la mejor forma de tomar las decisiones pedagógicas oportunas, adaptándose en cada momento al estudiante.

El módulo entorno gestiona la interacción de las otras componentes del sistema y controla la interfaz persona-computadora.

III. RAZONAMIENTO BASADO EN CASOS

El Razonamiento Basado en Casos (RBC) [26], [27], es un enfoque que aborda nuevos problemas tomando como referencia problemas similares resueltos en el pasado. De modo que problemas similares tienen soluciones similares, y la similitud juega un rol esencial [28]. Sus componentes fundamentales son la base de casos, el módulo de recuperación de casos y el módulo de adaptación de las soluciones.

La Base de Casos (Base de Casos) contiene las experiencias, ejemplos o casos a partir de los cuales el sistema hace sus inferencias. Esta base puede ser generada a partir de casos o ejemplos resultantes del trabajo de expertos humanos o por un procedimiento automático o semiautomático que construye los casos desde datos existentes registrados.

En el módulo de recuperación se recuperan de la Base de Casos los casos más semejantes al problema. No existe una medida de semejanza única, general, para cualquier dominio, de ahí que la eficiencia del sistema radica en la función de semejanza que se defina.

Después de la determinación de los casos más semejantes, las soluciones contenidas en dichos casos pueden usarse directamente como solución al nuevo problema, pero comúnmente necesitan ser modificadas.

El enfoque que utilizan los Sistemas Basado en Casos (SBC) para la adquisición de conocimiento es una de las ventajas que se le acreditan a este tipo de sistemas; pues razonan desde episodios específicos, lo cual evita el problema de descomponer el conocimiento del dominio y generalizarlo en reglas.

Otras de las ventajas de los SBC están fundamentadas; en la flexibilidad para representar el conocimiento a través de los casos, la organización de la BC y de las estrategias de recuperación y adaptación de los casos y que el usuario puede ser capaz de agregar nuevos casos a la BC sin la intervención experta.

Ventajas lo son también, el reuso de las soluciones previas al resolver un problema, y el almacenar casos que resultó un fracaso, lo que permite advertir sobre problemas potenciales a

evitar. Así como también poder fundamentar las soluciones derivadas a partir de casos reales.

Las limitantes de los SBC están en la definición de la función de semejanza y en lo difícil que resulta encontrar una estructura apropiada para describir el contenido de un caso y decidir cómo la memoria de casos debe ser organizada e indexada para un almacenamiento, recuperación y reuso efectivo.

IV. CARACTERÍSTICAS GENERALES DEL MODELO PARA ELABORAR SEAI USANDO RAZONAMIENTO BASADO EN CASOS

El esquema en forma de mapa conceptual que ilustra la figura 1 muestra la estructura general del modelo que se describe en este artículo.

Los casos en la BC representan el estado del conocimiento y comportamiento del estudiante, así como el entrenador o material didáctico más adecuado. Cada caso es un ejemplo de modelado de estudiante, el cual se divide en modelo del estudiante (rasgos predictores), materiales didácticos más adecuados para ese modelo de estudiante (rasgo objetivo). Dado un nuevo estudiante se diagnostica usando el paradigma del RBC los entrenadores sugeridos para el mismo, adaptados a sus conocimientos y comportamientos.

Los rasgos predictores reflejan el estado cognitivo, el estado afectivo y otros elementos de interés sobre el estudiante. No se limita el número de rasgos para caracterizar el estado cognitivo y afectivo del estudiante. Cada rasgo tiene un valor asociado y una medida de certeza. El rasgo objetivo es un rasgo multievaluado, los valores del mismo se corresponden con los materiales didácticos propuestos para ese modelo de estudiante sugiriendo un orden.

Los rasgos predictores, contienen los datos de entrada, o sea la información a partir de la cual el sistema infiere el estado del estudiante, ya sea cognitivo, afectivo-motivacional u otras características que se consideren importantes a tener en cuenta en el SEAI que se desarrolla.

El dominio del rasgo objetivo es el conjunto de entrenadores diseñados por los profesores que se adecuan a las características de los estudiantes. La propuesta de estos entrenadores puede estar dada usando criterios de expertos o utilizando algún método de clasificación no supervisada para determinar el número de grupos en que están asociados los modelos de estudiantes descritos en la base de casos y proponer para cada grupo un conjunto de entrenadores.

La organización de la base de casos se define mediante una estructura jerárquica de grupos, representados cada uno de los grupos por el elemento de mayor tipicidad de los mismos, en un nivel superior. Esta forma de organizar los casos favorece el acceso y recuperación de los casos.

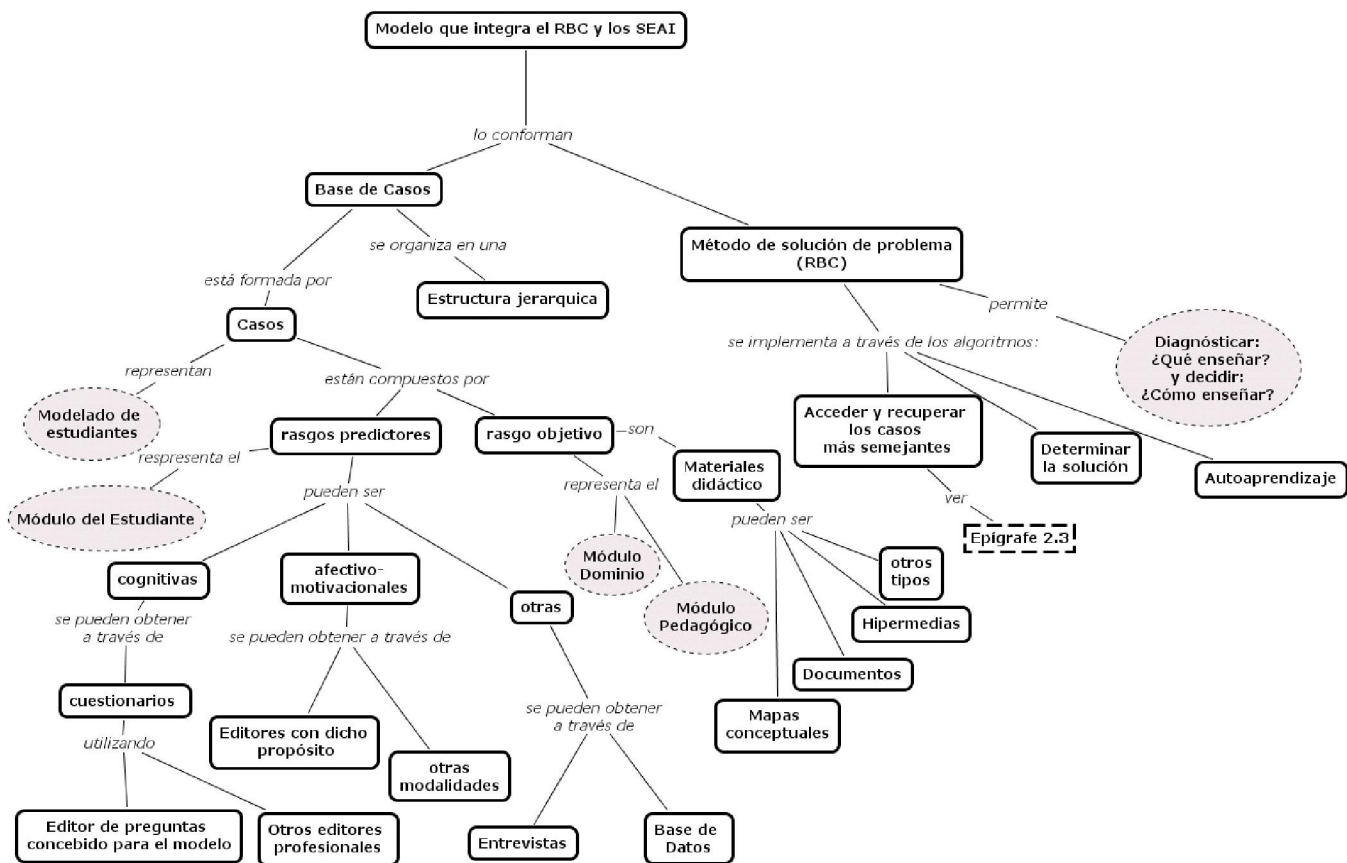


Figura 1. Esquema general del modelo

A. Definición de los rasgos predictores a través de cuestionarios

Para la obtención de los rasgos predictores a partir de cuestionarios se aplican n preguntas, cuyas respuestas son binarias (0 / 1), obteniéndose una tabla de $n+1$ columnas y $2n$ filas. La columna $n+1$ se corresponde con la evaluación del rasgo, que se obtiene por una escala valorativa según criterio de expertos: 0 (incorrecta) y 1 (correcta) o bien, regular y mal ó 5, 4, 3, 2; entre otras.

La evaluación (columna $n+1$) puede tomar valores iguales para combinaciones de respuestas diferentes, por lo que se hace necesario diferenciar este valor según una u otra combinación de respuestas. A esta diferencia se le llama en lo adelante grado de certeza, que puede ser vista como el grado de pertenencia del rasgo al valor que toma.

Selección de preguntas relevantes

Para determinar la importancia de cada una de las preguntas y detectar la existencia de preguntas superfluas que no determinen en la evaluación del rasgo se utiliza un algoritmo de selección de rasgos.

Ningún algoritmo o técnica de selección de rasgos es mejor que otra de forma general. En este problema se trabaja con

matrices cuya dimensión máxima es de 5×25 por lo que se considera que los algoritmos basados en el enfoque lógico combinatorio son apropiados, puesto que la limitante principal que se le señala a este enfoque no está presente, debido a que el costo computacional no es muy grande. El análisis que se describe en [29] sobre el comportamiento de diferentes algoritmos del enfoque lógico combinatorio para el cálculo del conjunto de testores típicos para matrices de diferentes dimensiones corrobora la afirmación expuesta anteriormente.

Se elige como algoritmo selector de rasgos el algoritmo FS - testores que se presenta en [30]; ya que permite hacer la diferenciación completa de objetos de clases no necesariamente disjuntas.

El algoritmo 1, publicado en [31], trabaja a partir de una matriz de aprendizaje (MA) como ilustra la figura 3, donde n es la cantidad de preguntas, m las variantes de respuestas, $?$ la cantidad de clases de evaluación y $R = \{x_1, x_2, \dots, x_n\}$ el conjunto de todas las preguntas del cuestionario para evaluar al rasgo predictor.

	x_1, \dots, x_n	$\alpha_1, \dots, \alpha_\theta$
O1	$x_1(O1), \dots, x_n(O1)$	$\alpha_1(O1), \dots, \alpha_\theta(O1)$
\vdots	\vdots	\vdots
Om	$x_1(Om), \dots, x_n(Om)$	$\alpha_1(Om), \dots, \alpha_\theta(Om)$

Figura 2. Matriz de Aprendizaje.

ai se obtiene:

$$\alpha_i(O_j) = \frac{\sum_{i=1}^n \delta_i(O_i, O') \sum_{i=1}^n \varepsilon_i \delta_i(O_i, O')}{\frac{n^2 (n+1)}{2}} \quad 1$$

donde n es la cantidad de preguntas, O' es el ejemplar de cada clase que se obtiene por criterio de experto, ε_i es el peso de la pregunta i , que se hace corresponder con la posición i y δ_i es la función de comparación por rasgos.

Algoritmo 1. Selección de preguntas relevantes

Entrada: Matriz de Aprendizaje.

Salida: Conjunto de preguntas relevantes.

P1: Cálculo de los FS -testores

P2₁: Calcular todos los FS -diferenciante.

P2₂: Calcular todos los FS -caracterizantes a partir del conjunto de los FS -diferenciantes.

P2₃: Obtener el conjunto de los FS -testores.

P2. Selección de las preguntas relevantes.

P3₁: Para cada pregunta i que pertenece al menos a un FS -testor calcular:

$$P(x_i) = \frac{T_i}{|T|}, \text{ donde}$$

T_i : número de testores típicos donde aparece la pregunta (rasgo) i .

$|T|$: número de testores típicos.

P3₂: Para cada FS -testor calcular:

$$\psi_j(t) = \sum_{i \in t} \varepsilon_i(t), \text{ en otras palabras, suma de la}$$

importancia de las preguntas que componen el FS -testor.

P3₂: Seleccionar el FS -testor de mayor $\psi_j(t)$

Algoritmo 2. Cálculo del valor y grado de certeza de los rasgos predictores

Entrada: Valor de las respuestas dadas a las preguntas del rasgo predictor, el cual representa un conocimiento de un contenido específico.

Salida: valor del rasgo predictor y grado de certeza asociado.

P1: Calcular α_i para cada ejemplar O' del rasgo predictor.

P2: Seleccionar el mayor α_i y asignar al valor del rasgo predictor el valor de la clase i y como grado de certeza el valor α_i

El algoritmo 2 describe un método para el cálculo del grado de certeza, asociado al valor de un rasgo, que se obtiene a partir de un cuestionario, no referenciado en la literatura consultada. Esta forma de obtener el valor de los rasgos predictores es común en los SEAI.

Representación de la base de casos mediante una estructura de árbol.

La base de casos debe facilitar el acceso y recuperación a los casos semejantes, por tanto es importante determinar cómo organizarla.

En el modelo se propone el uso de una estructura jerárquica con características diferentes a las reportadas en la literatura científica consultada. Esta estructura se concibe a partir de formación de grupos. Se forman grupos atendiendo a la medida de similitud existente entre casos, evaluando esta desde un subconjunto de rasgos predictores. Posteriormente se determina el elemento típico del grupo que queda en un nivel superior.

Se utiliza el algoritmo LEX [29], del enfoque lógico combinatorio para seleccionar los rasgos predictores relevantes.

La aplicación del algoritmo LEX permite obtener el conjunto de los testores típicos (conjunto minimal de rasgos que permite diferenciar objetos de clases distintas) y a partir de éstos calcular la importancia de los rasgos predictores, como se describe en el algoritmo 3.

Algoritmos para construir el modelo de la Base de Casos.

Para construir la base de casos se requiere identificar los rasgos importantes y grado de certeza de cada uno de ellos (algoritmo 3) y construir la estructura jerárquica de la misma (algoritmo 4), expliquemos estos dos algoritmos.

Algoritmo 3. Selección de los rasgos predictores relevantes y cálculo de su importancia.

Entrada: BC.

Salida: Conjunto de rasgos relevantes y su importancia.

T1: Formar la Matriz Básica (MB).

T2: Seleccionar el conjunto de testores típicos utilizando el algoritmo LEX.

T3: Calcular el peso de los rasgos que aparecen en la familia de testores típicos:

$$P(x_i) = \frac{T_i}{|T|} \quad L(x_i) = \frac{\sum_{t \in T} \frac{1}{|T_i|}}{|T|}, \text{ donde}$$

T_i : número de testores típicos donde aparece la pregunta (rasgo) i .

$|T|$: número de testores típicos.

$|T_i|$: número de rasgos que forman el testor T_i

$$\varepsilon_i(x_i) = \alpha P_i(x_i) + \beta L_i(x_i),$$

donde $\alpha > 0$, $\beta > 0$ y $\alpha + \beta = 1$. α y β son dos parámetros que ponderan la participación o influencia de P_i (frecuencia de aparición) y L_i (longitud de los testores) respectivamente en ε . En el modelo se consideran $\alpha = \beta = 0.5$.

T4: Selección del conjunto de rasgos relevantes:

a. Para cada testor típico t_i calcular:

$$\psi_i(t_i) = \sum_{j=1}^{|t_i|} \varepsilon(x_j), \text{ en otras palabras, la magnitud}$$

calculada es la suma de la importancia de las preguntas que componen el testor típico.

b. Seleccionar el testor típico de mayor $\psi_i(t)$, compuesto por los rasgos relevantes.

El modelo jerárquico de la BC se construye a partir del algoritmo 4. Para concebir este modelo se utilizan criterios agrupacionales del enfoque lógico combinatorio sin aprendizaje donde los casos se organizan en grupos sobre la base de criterios de semejanza definidos. Se identifican los casos en diferentes agrupaciones, donde estas se generan de manera “natural” según el comportamiento global o particular de las semejanzas entre los casos o atendiendo al cumplimiento de una cierta propiedad. No se necesita tener a priori ninguna información al respecto de las agrupaciones.

Para cada grupo de casos se determina el caso “representante del grupo”, que se corresponde con el caso que más se parece a los restantes casos de su grupo, idea que se aborda en diferentes trabajos del enfoque lógico combinatorio y en especial en el algoritmo HOLOTIPO [32].

Aplicar de forma recursiva el algoritmo 4 es una alternativa para organizar la BC en una estructura jerárquica.

Algoritmo 4. Organización jerárquica de la BC

Entrada: BC y conjunto de rasgos relevantes seleccionados con el algoritmo 2.

Salida: BC' (conjuntos anidados).

M1: Construir la Matriz de Semejanza¹.

M2: Calcular el umbral de semejanza β_0 :

$$\beta_0 = \frac{2}{m(m-1)} \sum_{i=1}^{m-1} \sum_{j=i+1}^m \beta(O_i, O_j), \text{ donde } m: \text{ número de casos, } i \text{ y } j \text{ recorren las filas y columnas respectivamente.}$$

M3: Agrupar siguiendo el criterio agrupacional: b_0 -compactos descrito en el anexo 1.

M4: Determinar el típico de cada grupo:

$$t(O_i) = \frac{\beta_i}{\frac{1}{|G|-1} * \sum_{j \neq i} (\beta_i - \beta(O_i, O_j))} \quad 2$$

donde $|G|$: cardinalidad del grupo, $j = 1 \dots |G|$, β_i mayor valor de semejanza entre O_i y los restantes elementos del grupo y

$$\beta(O_i, O_j) = \frac{\sum_{i=1}^n \varepsilon_i \delta_i(x_i(O_i), x_i(O_j)) (1 - |\mu_i(O_i) - \mu_i(O_j)|)}{\sum_{i=1}^n \varepsilon_i} \quad 3$$

donde ε_i : importancia del rasgo, μ_i : grado de certeza asociado al valor del rasgo, δ_i : función de comparación del rasgo i .

M5: Obtener otro nivel de agrupamiento.

En la figura 3 se muestra el árbol que representa la BC cuyos nodos interiores representan los típicos de los grupos y las hojas, es decir el último nivel de agrupamiento representan grupos de casos.

1. Matriz que se obtiene como resultado de comparar todos los objetos de la matriz de aprendizaje.

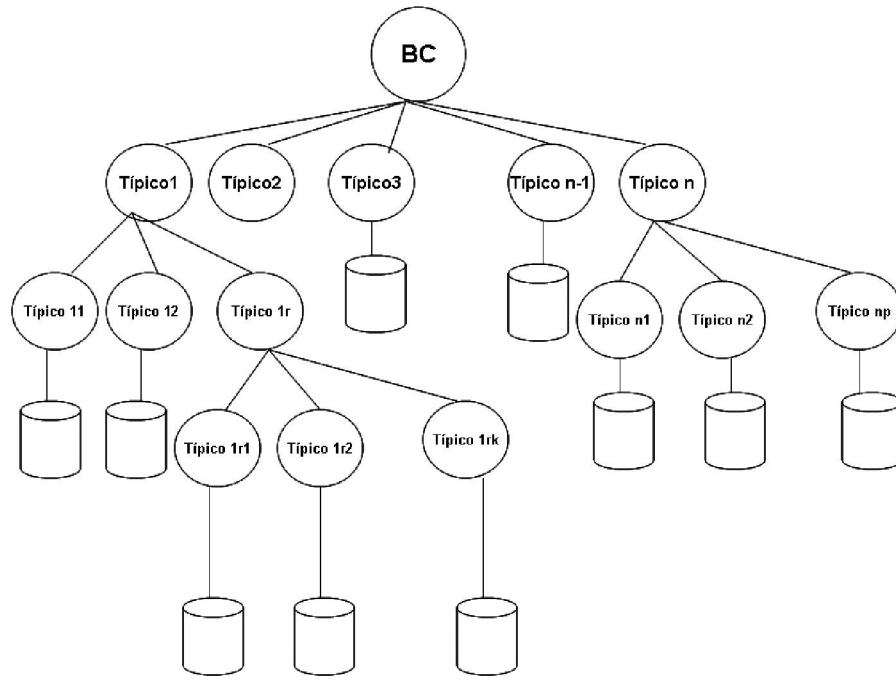


Figura 3. Esquema del modelo de la Base de Casos con más de un nivel de jerarquía.

Acceso y Recuperación de los casos relevantes

Los procesos de recuperación y adaptación son los responsables de la obtención del nuevo caso, donde los rasgos predictores se valorizan por uno de los métodos establecidos.

El procedimiento de recuperación consta de dos etapas: acceso y recuperación.

En la etapa de acceso se seleccionan los casos potenciales para el proceso de recuperación. La estructura de representación propuesta permite reducir el número de casos a considerar durante el acceso y recuperación, pues sólo se trabaja con aquellos casos que se encuentran en el grupo cuyo típico es el mas similar al nuevo caso (el caso a resolver se compara con los típicos del primer nivel de jerarquía).

En ocasiones el emparejamiento del nuevo problema y los casos de la base no es perfecto debido a que, por una parte los valores de los rasgos predictores del nuevo problema y los casos previos almacenados en la base no son exactamente iguales y por otra existen valores omitidos en algunos de los rasgos. Un enfoque usual para resolver este problema el cual se sigue en este trabajo es definir una función de semejanza o de distancia.

Comenzando a partir del primer nodo, se va comparando el nuevo caso con el típico y así sucesivamente a través del campo del siguiente hermano se repite este proceso hasta que el campo tome el valor nulo. Terminado este proceso se selecciona el nodo cuya comparación del nuevo caso con el típico resultó el valor de semejanza mayor. Si el campo primer hijo es válido significa que existe otro nivel de agrupamiento y se repite el

proceso antes descrito. En otro caso significa que ya se puede acceder al grupo de casos que representa el típico y seleccionar los casos más semejantes al nuevo caso.

Algoritmo 5. Acceso a los casos más semejantes

Entrada: Problema a resolver: O_0 y BC .

Salida: Conjunto de casos potenciales para la recuperación dado $O_0 : Pt(O_0)$.

A1: Calcular $\beta(O_0, O_i)$, O_i representa el típico de cada grupo.

A2: Seleccionar cuyo valor de es el mayor.

A3: Si el típico seleccionado tiene otro nivel de agrupamiento ir a **A1**; si no asignar a $Pt(O_0)$ el grupo de casos representados por el típico O_i (ver figura 3).

De esta forma en el conjunto quedan los casos potenciales a recuperar para dar solución al caso O_i .

Algoritmo 6. Recuperación de los casos más semejantes

Entrada: O_0 , $Pt(O_0)$, k (número de casos a recuperar).

Salida: K Conjunto de casos recuperados.

R1: $\forall O_i \in Pt(O_0)$ determinar: $\beta(O_0, O_i)$.

R2: Formar el conjunto K con los k casos más semejantes (k -vecinos más cercanos).

Determinación de la decisión

Una vez seleccionados los casos más semejantes es posible que estos propongan soluciones diferentes por lo que se hace necesario determinar cuál de ellas debe tomarse.

En el modelo, se modifica el criterio de adaptación planteado en (Wilke 1996), obteniéndose así una nueva alternativa para determinar el caso óptimo entre los casos recuperados y a partir de él tomar la decisión adecuada.

Este criterio de optimalidad se da a través de una función que combina de forma ponderada el valor de la semejanza entre el nuevo problema y el caso recuperado y el grado de certeza de la solución del caso recuperado.

Desde el punto de vista de la teoría de la toma de decisiones, el resultado de esta función puede ser vista como la utilidad esperada del caso, la cual permite establecer sus preferencias sobre un caso para tomar una decisión.

Algoritmo 7. Determinación de la decisión

Entrada: Nuevo caso O_0 y el conjunto de casos recuperados K .

Salida: Caso resuelto.

D1: $\forall O_t \in K, t = 1 \dots |K|$, calcular el grado de certeza del rasgo objetivo a partir de los grados de certezas del valor de los rasgos predictores:

$$\mu(O_t) = \frac{\sum_{i=1}^n \mu_i}{n}, \text{ donde } \mu_i \text{ es el grado de certeza del}$$

valor del rasgo y n es el número de rasgos predictores.

D2: $\forall O_t \in K, t = 1 \dots |K|$, determinar:

$$\psi(O_t) = \alpha \beta(O_o, O_t) + (1 - \alpha) \mu(O_t) \quad 4$$

A medida que α tiende a 1 significa que se le está dando mayor importancia a la semejanza que al grado de membresía de la solución. Se considera $\alpha = 0.5$.

D3: Asignar a \hat{e} máximo $(\psi(O_t))$.

D4: Formar el conjunto $K' = \{O_{t1}', O_{t2}', \dots, O_{tr}'\}$ con los $O_t \in K$ tales que $\psi(O_t) = \hat{e}$

D5: Si $|K'| = 1$ entonces

Asignar el valor del rasgo objetivo del caso $O_{t_i} \in K'$ al nuevo caso O_0 .

Si no asignar el valor del rasgo objetivo del caso $O_{t_i} \in K'$ y máximo $(\beta(O_0, O_{t_i}))$, al nuevo caso O_0 .

D6: Guardar el caso resuelto O_0 en $Q \subseteq K$.

Autoaprendizaje de la base de casos

El autoaprendizaje de la BC se logra con la incorporación de los nuevos problemas que se van resolviendo y en consulta con el usuario.

A partir de los nuevos problemas que se resuelven, desde el cual el sistema incorpora nuevos casos a la BC. Puede hacerse automáticamente o en consulta con el experto.

Algoritmo 8. Autoaprendizaje de la BC

Entrada: BC y Q conjunto de casos resueltos no almacenados.

Salida: BC reorganizada.

AA1: $BC = BC \cup Q$

AA2: Aplicar el algoritmo 3.

V. EFICIENCIA DEL MODELO

Para ilustrar los resultados de la validación del modelo propuesto en esta tesis se toman como muestra dos BC correspondientes a dos SEAI desarrollados utilizando el modelo descrito y dos BC experimentales que responde a características típicas de BC que se desarrollen utilizando este modelo, como aparecen descritas en la tabla 1.

Tabla 1. Características generales de las bases de casos

Base de Casos	No. de Casos	Rasgos Predictores	Número de Clases
Educación Ambiental	84	13	4 (5/4/3/2)
Grafos	37	7	3 (B/R/M)
BC Experimental 1	40	10	4 (5/4/3/2)
BC Experimental 2	80	13	3 (B/R/M)

La BC: Educación Ambiental (EA) sobre Humedales se obtiene del SEAI [33], dirigido por equipo multidisciplinario conformado por especialistas del Centro de Estudio e Informática y el Laboratorio de Propagación Masiva de Plantas del Instituto de Biotecnología de las Plantas de la Universidad Central de Las Villas. La BC: Grafos es la correspondiente al SEAI [34] que se desarrolló para apoyar el estudio de la teoría de grafos a estudiantes que cursan el segundo año de la carrera de Ciencias de la Computación y que ha sido utilizado como material complementario para el estudio independiente de este tema.

A. Análisis de la eficiencia en la recuperación de los casos más semejantes

El análisis de la eficiencia en la recuperación de los casos más semejantes del modelo propuesto que incluye implícitamente el cálculo del grado de certeza (algoritmo 2), la importancia de los rasgos predictores (algoritmo 3), acceso y recuperación de los casos más semejantes (algoritmos 5 y 6), se realiza teniendo en consideración los resultados obtenidos en la solución de nuevos problemas, usando la función de semejanza propuesta 3 y la función en su forma clásica (5).

$$f(w_i, \delta_i(x_i(O_0), x_i(O_t))) = \frac{\sum_{i=1}^n w_i \cdot \delta_i(x_i(O_0), x_i(O_t))}{\sum_{i=1}^n w_i} \quad 5$$

Para identificar estos dos procesos se denomina al primero NNB- N (Nuevo Modelo del Vecino más Cercano) y al segundo NNB-T (Modelo del Vecino más Cercano Tradicional).

Para llevar a cabo este proceso se utiliza el método de validación cruzada usando 10 subconjuntos (en inglés *10-fold cross validation*). Utilizando cada archivo de datos (tabla 1) se realiza el experimento cuyo resultado se muestra en la tabla 2.

La función de semejanza 3 que utiliza el modelo propuesto en esta tesis fue incluida en la herramienta de Aprendizaje Automatizado Weka.

Como puede apreciarse en los resultados que muestra la tabla 2 considerar el grado de certeza presente en los valores de los casos aumenta la eficiencia en el proceso de recuperación de los casos más semejantes; así como la toma de decisiones.

Tabla 2. Medidas de desempeño general.

Medidas de desempeño general	Bases de Datos							
	EA		Grafos		Experimental 1		Experimental 2	
	NNB-T	NNB-N	NNB-T	NNB-N	NNB-T	NNB-N	NNB-T	NNB-N
Instancias clasificadas correctamente (%)	88.09	94.04	86.48	97.29	75.25	92.5	73.75	96.25
Estadígrafo de Kappa	0.83	0.91	0.77	0.95	0.65	0.89	0.56	0.93
Media del error absoluto	0.05	0.02	0.09	0.01	0.12	0.03	0.17	0.02
Raíz del error cuadrático medio	0.24	0.17	0.30	0.13	0.35	0.19	0.41	0.15

Se hace un análisis a partir de los resultados obtenidos para la BC: EA. Como se muestra en la tabla 2 el porcentaje de casos clasificados correctamente es 94.04 % (de 84 casos, 79 correctos y cinco incorrectos).

Cuando se analiza la matriz de confusión y se hace un análisis de la clasificación por clases (5/4/3/2) se observa que todos los casos de las clases 5 son bien clasificados. Un caso de la clase 4 se clasifica como de la clase 3. En la clase 3, cuatro casos se clasifican como de la clase 2 y por último todos los casos de la clase 2 son correctamente clasificados. Desde el punto de vista

docente y teniendo en cuenta que los modelos de estudiantes se corresponden con la evaluación estipulada en el sistema de educación superior, este resultado se puede considerar satisfactorio.

B. Eficiencia del modelo de organización de la Base de Casos

En este sentido resulta de interés analizar la calidad del conjunto de casos potenciales. En este estudio, las BC: Educación Ambiental y Grafos se organizan de forma jerárquica siguiendo el algoritmo 4.

Tabla 3. Casos seleccionados para la Adaptación para la BC de ED.

Problema	ESTRUCTURA DE DATOS (ED)			
	Casos Seleccionados para la Adaptación (10 vecinos)			
	ESTRUCTURA PLANA	#	ESTRUCTURA JERÁRQUICA	#
Caso 3	54;57;65;34;41;46;47;19;13;23	10	34; 47; 23	3
Caso 11	15;69;51;73;74;68;17;53;67;70	10	53;67;70;15;51;69;74;73; 68;17	10
Caso 17	11;23;9;19;48;12;18;67;22; 84	10	84;67;54;48;18;22;11; 9;19;23	10
Caso 18	33;49;53;41;29;37;14;19;21;43	10	43;33;41;49;53;29;37;14;19;21	10
Caso 42	26;34;70;79;17;22;76;18;31;38	10	70;79	2
Caso 55	23;79;1; 9;5;12; 38; 50; 51;59	10	26;12;38	3
Caso 59	28;72;10;43;65;67; 20;6;21;22	10	28;47;73	3
Caso 61	57;60;65;34;41;47;73;18;34;68	10	57;60; 65; 34;41;47;73;18;34;68	10
Caso 71	11;13;54;62;9;79;81;18;19;22	10	35;13;54;62;10;18;22;11;9	9
Caso 84	12;15;90;33;38;43;18;12;20;35	10	20; 33; 38; 12; 52; 58	6

Para cada par de BC (organizada en una estructura plana y organizada en forma jerárquica) dado un nuevo problema, se realiza la recuperación de los 10 casos más semejantes utilizando la función de semejanza 3 y se comparan estos dos conjuntos de casos, así como también las decisiones (elemento que se resalta en la tabla) que ellos proponen en el proceso de adaptación en condiciones de incertidumbre (Algoritmo 7).

El experimento se realiza para 10 casos seleccionados de forma aleatoria entre los almacenados en la BC. La información relacionada con el experimento se refleja en las tablas 3 y 4.

Las tablas 3 y 4 muestran que un elevado porcentaje del conjunto de casos potenciales de la BC organizada

jerárquicamente, que se utilizan para la adaptación, están incluidos en el conjunto de casos que se usan cuando se realiza la búsqueda en la BC organizada en una estructura plana.

La cantidad de casos con los que se compara en la estructura plana es siempre 10 (10 vecino más cercano). Con la estructura jerárquica, para cada caso se realizan como máximo 10 comparaciones. Ambas tablas muestran casos en los que este número se reduce considerablemente. Con el objetivo de cuantificar tal reducción se aplicó la prueba exacta del test no paramétrico de Wilcoxon y se obtuvo una significación de 0.000. Este valor prueba que la reducción en el número de comparaciones es significativa.

Tabla 4. Casos seleccionados para la Adaptación para la BC de Grafos.

Problema	Grafos			
	Casos Seleccionados para la Adaptación (10 vecinos)			
	Estructura Plana	#	estructura jerárquica	#
Caso 3	4; 35;11;21;37;8;7;32;9 8	10	4;35;11;21;37;8;7;32;9;8	10
Caso 8	1;13;23;7;18;26;19;2;15;21	10	1;13;7;18;26;19;2;15	8
Caso 15	8; 5; 6; 34; 10; 28;36; 12; 16	10	4;12;16	3
Caso 17	6;18;2;3;6;7;4;10;8;14	10	6;3;4;10;14	5
Caso 19	12;14;29;9;1;10;2;11;14;16	10	12;14;11;14;29;9;10;1;2;16	10
Caso 25	6;18;2;3;6;7;4;10;8;14	10	6;3;4;10;14	5
Caso 27	8;4; 5; 6; 9; 10; 28; 36;15;16	10	4; 28;16	3
Caso 31	5;8;14;27;22;32;11;8;9;1	10	9;27;11	3
Caso 33	1;16;21;20;34;12;16;24;15;31	10	20;1;16;21;34;15;31;18	8
Caso 36	13;21;33;3;7;9;14;25;19;6	10	13;33;9;14;19;6	6

La reducción de la cantidad de comparaciones es un resultado bueno, pero no suficiente. Debe demostrarse además que la calidad de la respuesta no se afecta. Para probarlo, se cuantificó la cantidad de veces en los que la respuesta coincidió (19 veces) y la cantidad en las que no coincidió (una vez). Se aplicó un test chi cuadrado de bondad de ajuste y el resultado fue altamente significativo (0.000), lo que demuestra que la calidad de la respuesta en la estructura jerárquica no se afectó.

Solo cuando se presenta como nuevo problema el caso 71 (tabla 2) la solución propuesta no coincide; al calcular el grado de semejanza entre ambas propuesta utilizando la función de semejanza 3, se obtiene el valor 0.92, lo que muestra que no es significativa la diferencia entre las soluciones dadas.

Esto significa que la estructura propuesta aumenta la eficiencia en el acceso, al disminuir el número de casos que se utilizan en el proceso de recuperación, conservando la eficiencia en la búsqueda de soluciones.

Son resultados también de esta investigación, expuestos en otros artículos científicos, la implementación del modelo propuesto en la herramienta de autor HESEI que facilita el desarrollo de SEAI en aplicaciones específicas a la medida del usuario final. Y la guía metodológica definida para orientar a los docentes en el proceso de ingeniería del conocimiento implícito en el desarrollo de un SEAI, con la herramienta computacional HESEI.

VI. CONCLUSIONES

Los resultados obtenidos permiten concluir que:

1. Un modelo que integre el Razonamiento Basado en Casos y los SEAI favorece la implementación de las componentes fundamentales de este tipo de sistemas de enseñanza-aprendizaje en cualquier área del saber, de ahí la factibilidad del modelo empleado. La representación de los casos permite integrar el modelo del estudiante y las propuestas de medios sugeridos al estudiante de acuerdo a sus características individuales.
2. El modelo propuesto integra las 3 componentes de un SEAI. En cada caso se describe el modelo del estudiante y su modelado. El razonador basado en casos determina la decisión a tomar para lograr el aprendizaje interactivo-individualizado atendiendo a las características del estudiante sobre la base de una selección adecuada de las mismas, quedando propuesto que se enseña y como se enseña.
3. La utilización de una función de semejanza adaptada al modelo del estudiante permite la recuperación de los k modelos del estudiante más similares a la descripción del estudiante presentado. Para la obtención de los k más similares se ponderan atendiendo a su importancia de cada rasgo y la certeza con que se alcanza cada valor, se manejan

sus rasgos cognitivos, afectivos-motivacionales u otras características personales del estudiante

4. La organización jerárquica propuesta favorece los procesos de acceso, recuperación sin que se afecte los resultados que se alcanzan en la propuesta de la decisión, balance entre eficiencia y eficacia

REFERENCIAS BIBLIOGRÁFICAS

1. Guida, G. and Tasso, C., 1994. Design and Development of Knowledge- Based Systems. From Life Cycle to Methodology. John Wiley and Sons Ltd., Basing Lane, Chichester, England.,
2. Bello, R., 2002. Aplicaciones de la Inteligencia Artificial. Ediciones de la Noche, Guadalajara, Jalisco, México. ISBN: 970-27-0177-5.
3. Hand, D.J., 1997. Construction and Assessment of Classification Rules. John Wiley & Sons, Chichester, UK.,
4. Rich, E., 1988. Inteligencia Artificial. Edit. Gustavo Gili, S.A., Barcelona.
5. Minka, T.P., 2001. Expectation propagation for approximate Bayesian inference. In Proceedings of the 17th Annual Conference on Uncertainty in AI (UAI), pp. 362-369.
6. Lerner, U., 2002. Hybrid Bayesian Networks for Reasoning about Complex Systems. url: citeseer.nj.nec.com/lerner02hybrid.html.
7. Hilera, J. and Martínez, V., 1995. Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones. Addison-Wesley.
8. Ohno-Machado, L., 1996. Medical Applications of Neural Networks: Connectionist Models of Survival. PhD dissertation, Stanford University, Department of Computer Science. Report STAN-CS-TR-96-1564.
9. Dutta, S. and Bonissone, P., 1991. Integrating Case-Based and Rule-Based Reasoning: the Possibilistic Connection. In Uncertainty in Artificial Intelligence 6, pp. 281-298, P.P. Bonissone, M. Henrion, L.N. Kanal, J.F. Lemmer (editors), North-Holland.
10. García, M. and Bello, R., 1997. El empleo del razonamiento basado en casos en el desarrollo de Sistemas basados en el conocimiento para el diagnóstico. Trabajo de Tesis en opción al grado científico de Doctor en Ciencias Técnicas., UCLV.
11. Gutiérrez, I. and Bello, R., 2003. Modelo para la Toma de Decisiones usando Razonamiento Basado en Casos en condiciones de Incertidumbre. Trabajo de Tesis en opción al grado científico de Doctor en Ciencias Técnicas.UCLV.
12. Shneiderman, B., 2006. Diseño de interfaces de usuario. Estrategias para una interacción personacomputadora efectiva. Mexico: Addison Wesley.
13. Sierra, E., García-Martínez, R., Hossian, A., Britos, P. y Balbuena, E., 2006. Providing Intelligent User-Adapted Control Strategies in Building Environments. Research in Computing Science Journal. ISSN 1665-9899. Volumen 19. pp.. 235-241.
14. Gómez, H., 2008. COBBER: Un Enfoque Sistémico, Afectivo y Ontológico para el Razonamiento Basado en Casos Conversacional. Memoria que presenta para optar al grado de Doctor en Informática. Departamento de Ingeniería del Software e Inteligencia Artificial. Facultad de Informática. Universidad Complutense de Madrid.
15. Cataldi, Z. and F.J. Lage, 2009. Sistemas tutores inteligentes orientados a la enseñanza para la comprensión. EDUCATEC. Revista Electrónica de Tecnología Educativa. Número 28/Marzo 2009. ISSN:1135-9250. <http://educatec.rediris.es/revelec2/revelec28/>.
16. Ovalle, D. et al., 2007. Análisis funcional de la estrategia de aprendizaje individualizado adaptativo. Proyecto de investigación - DIME - Vicerrectoría de Investigación. Modelo de sistema multiagente de cursos adaptativos integrados con ambientes colaborativos de aprendizaje.
17. Graf, S., 2005. Improving student modeling: The relationship between learning styles and cognitive traits. pp. 37-44.
18. Carmona, M.E. and G. Castillo, 2007. Discovering student preferences in e-learning.
19. Beck, J.E., 2007. Difficulties in inferring student knowledge from observations (and why you should care). pp. 21-30.
20. González, H., N. Duque, and D. Ovalle, 2008. Modelo del estudiante para sistemas adaptativos de educación virtual. Revista de Avances en Sistemas e Informática, Vol. 5 No. 1, Edición especial Medellín, Mayo 2008, ISSN 1657-7663. III Congreso Colombiano de Computación -3CCC.
21. Durán, E.B., 2006. Modelo del alumno en sistemas de aprendizaje colaborativo. WAIFE.
22. Duque, N., 2007. Prpuesta de Doctorado en Ingeniería de Sistemas. Universidad Nacional de Colombia. Sede en Medellín. 34 P.
23. Hatzilygeroudis, I. and J.I. Prentza, 2004. Knowledge Representation Requirements for Intelligent Tutoring Systems. Proceedings of 7th International Conference Intelligent Tutoring Systems, ITS2004, Brasil.
24. Ming, G. and C. Quek, 2007. EpiList: An Intelligent tutoring system shell for implicit development of generic cognitive skills that support bottom-up knowledge construction. IEEE Transactions on Systems, Man & Cybernetics: Part A, 37(1).
25. Jiménez, J. and Ovalle, D., 2004. Entorno Integrado de Enseñanza/ Aprendizaje basado en ITS & CSCL. Revista Iberoamericana de Sistemas, Cibernética e Informática, USA, 1(1).
26. Aamodt, A. and P. E., 1994. Case-based reasoning: Foundational issues, methodological variations, and system approaches. AI Communications 7(1), 39-59.
27. López de Mántaras, R., 2005. Retrieval, reuse, revision, and retention in case based reasoning. The Knowledge Engineering Review, Vol. 00:0, 1-2. 2005, Cambridge University Press DOI: 10.1017/S0000000000000000 Printed in the United Kingdom.
28. Rodríguez, Y. and M. García, 2007. Generalización de la métrica basada en la diferencia de valores (VDM) para variables lingüísticas y su aplicación en sistemas basados en el conocimiento. Tesis presentada en opción del grado científico de Doctor en Ciencias Técnicas. UCLV.
29. Pons, A., 2003. LEX: Un nuevo algoritmo para el cálculo de los testores típicos. Revista Ciencias Matemáticas. Cuba.
30. Guevara, M., 2006. Uso de algoritmos genéticos y el concepto de Testor para la Selección de Variables.
31. Martínez, N., León, M. and García, Z., 2007. Features selection through FS-testors in Case-Based Systems of Teaching-Learning. MICAI-2007. International Conference on ARTIFICIAL INTELLIGENCE, LNAI 4827, pp. 1206-1217, Springer-Verlag Berlin Heidelberg 2007. A. Gelbukh and A.F. Kuri Morales.
32. Ruiz, J., 1993. Modelos Matemáticos para el Reconocimiento de Patrones. Edit. UCLV.
33. León, E.M., et al., 2008. Sistema de Enseñanza-Aprendizaje Inteligente Sobre Humedales Para La Educación Ambiental. Conferencia UNIVERSIDAD 2008 Provincial.
34. Martínez, N., et al., 2007. Sistema de enseñanza/aprendizaje inteligente para grafos. ALME 20 (Acta Latinoamericana de Matemática Educativa, Volumen 20. ISBN: 978970-9971-13-2. www.clame.org.mx.

Universidad Nacional de Colombia Sede Medellín

Facultad de Minas



Escuela de Ingeniería de Sistemas

Grupos de Investigación

Grupo de Investigación en Sistemas e Informática

Categoría A de Excelencia Colciencias
2004 - 2006 y 2000.

GIDIA: Grupo de Investigación y Desarrollo en Inteligencia Artificial

Categoría A de Excelencia Colciencias
2006 – 2009.



Grupo de Ingeniería de Software

Categoría C Colciencias 2006.

Grupo de Finanzas Computacionales

Categoría C Colciencias 2006.

Centro de Excelencia en Complejidad

Colciencias 2006

Escuela de Ingeniería de Sistemas
Dirección Postal:
Carrera 80 No. 65 - 223 Bloque M8A
Facultad de Minas. Medellín - Colombia
Tel: (574) 4255350 Fax: (574) 4255365
Email: esistema@unalmed.edu.co
<http://pisis.unalmed.edu.co/>

