

Lógica Difusa aplicada al Modelo del Estudiante de un Sistema Tutorial Inteligente

C. Huapaya⁽¹⁾, L. Lanzarini⁽²⁾, F. Lizarralde⁽¹⁾, G. Arona⁽¹⁾

⁽¹⁾ Centro de Investigación en Procesos Básicos, Metodologías y Educación
Facultad Ingeniería-Psicología. UNMDP

huapaya@fi.mdp.edu.ar

flizarra@fi.mdp.edu.ar

grarona@fi.mdp.edu.ar

⁽²⁾ Instituto de Investigación en Informática LIDI

Facultad de Informática. UNLP

[{laural@lidi.info.unlp.edu.ar}](mailto:laural@lidi.info.unlp.edu.ar)

Resumen

Un Sistema Tutorial Inteligente (STI) provee de instrucción personalizada al estudiante así como de apoyo durante el proceso de aprendizaje. Esta actividad implica la evaluación de los logros a medida que son alcanzados. A fin de tratar la ambigüedad propia de la evaluación humana de los objetivos instruccionales, se presenta un diseño del Modelo del Estudiante que utiliza lógica difusa con el objetivo de mejorar los métodos estadísticos tradicionales y en consecuencia, alcanzar un mejor nivel de adaptación.

Se describen tres modelos que figuran en la literatura y un modelo propio basado en el trabajo de Ossi Nykänen. Se espera producir resultados que proporcionen más información que las notas tradicionales a fin de proporcionar mejores datos al Módulo Tutorial del sistema.

Palabras claves: Sistemas Tutoriales Inteligentes, Modelo del estudiante, Lógica difusa, Diagnóstico adaptativo del estudiante

Sistemas Tutoriales Inteligentes

El objetivo de un Sistema Tutorial Inteligente es dar a una computadora la capacidad de

involucrarse en el proceso de enseñanza/aprendizaje usando técnicas de Inteligencia Artificial. En la concepción de estos sistemas el estudiante es central al diseño y desarrollo. La computadora se transforma en un instructor dinámico en lugar de un vehículo estático de información. El conocimiento que posea un STI le permite proveer asistencia a un aprendiz en forma parecida a un instructor humano. Un buen instructor tiene la habilidad de adaptar una lección a un estudiante individual a través del proceso de enseñanza. Uno de los objetivos principales de un STI debe ser alcanzar este nivel de instrucción individualizada.

La investigación actual en Sistemas Tutoriales Inteligentes busca diseñar sistemas de aprendizaje fundamentados en principios propios y en nuevas teorías de aprendizaje así como su implementación con herramientas actuales. La evolución del área ha ido desde diseños generales hacia aplicaciones específicas con nuevas tecnologías (especialmente agentes) y nuevos estilos de sistemas (ambientes y sistemas colaborativos).

En [1] se identifican los componentes de un STI y los denomina *módulo experto*, módulo de instrucción y currículo, y *módulo de diagnóstico del estudiante*. En 1988 [2] identificó, de manera similar, áreas como la

representación del conocimiento y metodologías de enseñanza. Estos tres componentes son referidos a menudo como la ‘Trinidad tradicional’ de un Sistema Tutorial Inteligente y son presentados a continuación:

- **Módulo experto (o dominio):** es el conocimiento del dominio (o tópicos del tema que será enseñado) incrustado en el sistema y representa el conocimiento del experto en el tema y las características de la resolución de problemas asociados.
- **Módulo del estudiante:** su función es capturar el entendimiento del aprendiz sobre el dominio.
- **Módulo tutorial:** contiene las estrategias tutoriales e instrucciones indispensables. Estas estrategias deben ajustarse a las necesidades del estudiante sin la intervención del tutor humano. El propósito principal de este módulo es reducir la diferencia del conocimiento entre el experto y el estudiante al mínimo.

Módulo del estudiante

El modelado del estudiante puede ser definido como la recolección de información relevante del estudiante (habilidades de aprendizaje, sus fortalezas, estilos de aprendizaje, errores cometidos, etc.) a fin de identificar y representar su estado de conocimiento. Este modelo debe poseer la habilidad de suministrar la ayuda individualizada que el estudiante requiera.

Como la enseñanza es un proceso dinámico, un STI debe actualizar su Modelo del Estudiante a medida que el estudiante avanza en su aprendizaje. Tal mantenimiento puede alcanzarse representando al estudiante de manera tal que sea fácilmente entendido y modificado por el STI. Se han presentado varios modelos en [3] y [4] a fin de interpretar el progreso del estudiante, incluyendo el diagnóstico de los errores, el seguimiento del estudiante a lo largo del tiempo y la representación de errores. Es quizás, el área de investigación más activa actualmente y la

que cuenta con importante logros. El objetivo perseguido es modificar la trinidad tradicional a fin de alcanzar la instrucción adaptativa.

Diagnóstico del estudiante

La calidad de la evaluación del conocimiento en los STIs se determina por la cobertura y exactitud de la información construida en el modelo del estudiante y la habilidad de actualizarlo dinámicamente. El proceso de inferencia de las características internas del estudiante a partir de su comportamiento observado durante la interacción hombre-máquina se llama *diagnóstico del estudiante* [5]. Este diagnóstico, que además involucra los juicios del evaluador, implica considerar los siguientes problemas:

1. Registrar el comportamiento observable del estudiante en términos de medidas específicas.
2. Inferir las características internas del conocimiento del estudiante en base a la información recogida, y además, que sean importantes para el aprendizaje.
3. Desarrollar un método para extraer esta información a través del monitoreo y seguimiento del estudiante.

El punto central de los desarrollos en esta área es investigar un método que pueda analizar efectivamente las mediciones de la actividad de los estudiantes y hacer estimaciones sobre sus características internas actualizando dinámicamente el modelo del estudiante. Este modelo es usado luego para guiar el comportamiento del sistema, por ejemplo, aconsejando al evaluador o guiando al estudiante.

Existen razones importantes para buscar nuevos métodos de evaluación del conocimiento del alumno, a saber:

- Puntuación imprecisa: los docentes asignan, al trabajo de los estudiantes, una

nota dentro de un esquema predeterminado. Esta nota puede diferir de un evaluador a otro, dependiendo de la experiencia y sensibilidad de cada uno de ellos. En general, la nota que se le asigna a un estudiante es una aproximación.

Otra forma de evaluar sus aptitudes, competencias y habilidades es calificarlos con términos lingüísticos como excelente, regular, etc. Se considera que aptitud, competencia y habilidad son conceptos imprecisos, como también lo son los términos excelente y regular. Puede presuponerse que etiquetas lingüísticas de carácter difuso puedan ser capturadas mejor usando técnicas difusas.

- Control de la calificación: usualmente, los docentes evalúan colocando una nota al logro de su estudiante. Casi nunca se usa un método de evaluación alternativo para verificar esa nota final del curso, con la cual se da por aprobado o desaprobado. Un nuevo método eficiente de evaluación puede resultar de gran utilidad para confirmar o refutar la decisión tomada con métodos tradicionales.
- Uso de la lengua natural en la evaluación académica: las pruebas pueden ser evaluadas usando términos lingüísticos y con ellos lograr mayor flexibilidad en el juicio sobre el logro del estudiante.

Además, en un modelo de evaluación educativa, donde no hay comunicación directa entre el docente y el alumno, la información que adquiere el sistema difiere de la que se obtiene de la comunicación cara a cara, donde la interacción es más rica y sin interferencias.

Información con incertidumbre

Siguiendo los lineamientos de los párrafos previos se infiere que uno de los principales obstáculos en el proceso de diagnóstico en un sistema computacional es la *incertidumbre*. Esta incertidumbre se origina en la naturaleza

abstracta de la cognición humana (p.e. la interpretación del docente sobre el rendimiento del estudiante medido generalmente con métodos estadísticos y aritméticos) y en el modo que el docente comunica sus preferencias y hábitos al sistema. Además, la adquisición de esta información produce datos sin elaborar, esto es, son datos que pierden precisión debido a la cuantificación posterior. La información registrada por el sistema incorpora estas inexactitudes. Posteriormente, los sistemas deben construir un método de decisión basado en datos imprecisos.

Breve introducción a la lógica difusa

El término lógica difusa [6,7,8] puede verse desde dos puntos de vista: el primero (más restringido) propone un sistema lógico cuyo objetivo es formalizar el razonamiento aproximado. Si bien la lógica difusa es una lógica multivaluada, no lo es en el sentido tradicional de los sistemas lógicos multivaluados. Los conceptos centrales son variables lingüísticas, formas canónicas, reglas if-then difusas, cuantificadores difusos y modos de razonamiento tales como razonamiento silogístico y razonamiento interpolatorio.

El segundo enfoque (más amplio) es casi sinónimo de teoría de los conjuntos difusos. Esta es una teoría de clases con bordes blandos y es más amplia que la lógica difusa en su sentido estricto; contiene, además, aritmética difusa, programación matemática difusa, teoría de grafos difusos, etc.

Los conjuntos difusos utilizan funciones, definidas desde un 'universo de objetos', X , en el intervalo $[0,1]$, i.e., la función $\mu: X \rightarrow [0,1]$ indica el grado de pertenencia de cada elemento al conjunto difuso A el cual se representa como $A = \{(x, \mu_A(x)) \mid x \in X\}$. De esta forma, $x \notin A$ se indica con el par $(x,0)$ y $x \in A$ con el par $(x,1)$. Nótese que si solo se establecen estos dos casos se obtiene la teoría tradicional de conjuntos, pero con la lógica difusa, es posible expresar el grado de

pertenencia de x al conjunto A con todos los valores intermedios entre 0 y 1. La función μ se la conoce como *función de pertenencia*.

Es importante notar que la especificación de la función de pertenencia es subjetiva, es decir, que los valores pueden diferir de una persona a otra; esta subjetividad proviene de las diferencias individuales en la percepción o expresión de conceptos abstractos. Este es el punto que diferencia la probabilidad (medida matemática de fenómenos aleatorios) de la posibilidad (subjetividad, i.e. un continuo psicológico).

La teoría de la lógica difusa busca proveer una notación matemática que permita expresar la incertidumbre asociada con los procesos cognitivos humanos.

La lógica difusa en el Modelo del estudiante

La lógica difusa es particularmente relevante para tratar fenómenos con incertidumbre y que involucran un cambio suave y progresivo. Por ejemplo, el razonamiento seguido durante un proceso de evaluación, se basa en un continuo cuyos extremos pueden denominarse, por ejemplo, “definitivamente competente” y “definitivamente incompetente” si se desea mensurar el nivel de pericia alcanzado.

Un alumno puede posicionarse, según algún criterio seguido de evaluación, en algún punto del continuo. El evaluador puede proponer distintas escalas para tomar decisiones, según el aspecto que desea medir. Por ejemplo, si se desea saber la “velocidad en la resolución de problemas” de un estudiante, puede pensarse en una escala cuyos extremos sean “rápido” y “lento”.

Los modelos difusos pueden ‘imitar’ el modo de adquirir conocimiento por parte de los docentes cuando evalúan las características de aprendizaje de sus alumnos, tales como actitudes, nivel de conocimiento, competencias, motivación y estilo de aprendizaje. En particular, la lógica difusa [9]

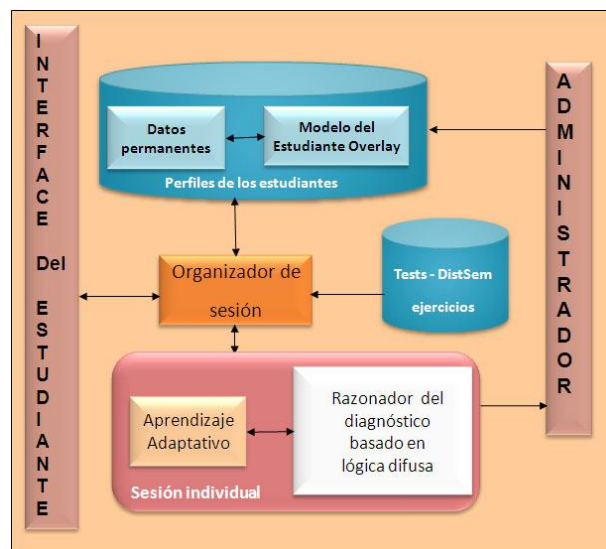


Figura 1: Modelo del estudiante de Infosem

y [10] es usada para acceder a un modo de razonamiento cualitativo cercano al razonamiento humano cuando toma decisiones, principalmente el manejo de la *imprecisión* y *vaguedad*. La forma de lograrlo es a través de la combinación de hechos difusos y relaciones difusas.

En el Modelo del Estudiante (ver figura 1) contiene el *perfil de los estudiantes*, el *organizador de la sesión individual* y el *repositorio de pruebas, problemas y ejercicios*. Cuando un estudiante interactúa con el STI se activa la *Sesión individual* donde se infiere que características debe tener el aprendizaje y la asistencia particular. En este trabajo nos hemos focalizado en el *Razonador del diagnóstico basado en lógica difusa*. El resultado de la sesión individual actualiza los datos del perfil del estudiante.

La evaluación humana del logro involucra, generalmente, términos lingüísticos como excelente, bueno, regular, etc. los cuales están fuertemente imbuidos de subjetividad. Estas etiquetas lingüísticas surgen a partir de diversos componentes de la evaluación como cuestionarios, planillas especializadas, etc. El evaluador propone estas etiquetas lingüísticas con las cuales el sistema debe llegar al diagnóstico.

Modelos difusos en el diagnóstico

En la literatura del área, existen varios desarrollos para la evaluación del estudiante basados en lógica difusa. Se presenta los correspondientes a Biswas, Law y Fourali:

Similitud difusa [11]: Biswas usó una función de equiparación (matching) S para medir el grado de similitud entre dos conjuntos difusos.

$$S(F, M) = \frac{\bar{F} \cdot \bar{M}}{\max(\bar{F} \cdot \bar{F}, \bar{M} \cdot \bar{M})}$$

donde F y M son conjuntos difusos y $S \in [0,1]$. \bar{F} y \bar{M} son dos vectores que representan a F y M y $F \cdot \bar{F}$ representa el producto escalar. Cuanto más grande sea el valor de S , mayor es la similitud entre los dos conjuntos. Dicha función fue aplicada a las respuestas escritas de los estudiantes. El algoritmo usado fue:

1. Crear conjuntos difusos estándar para las variables lingüísticas *Excelente*, *Muy bueno*, *Bueno*, *Satisfactorio* y *No Satisfactorio*.
2. Proponer puntos (o nota) a la pregunta i , P_i usando una planilla para las notas difusas (las filas representan el número de la pregunta y las columnas contienen los resultados correspondientes a la evaluación en términos difusos).
3. Calcular el grado de similitud entre P_i y el conjunto difuso.
4. Calcular los valores máximos y proponer la nota final.
5. Calcular la nota final total (sobre algunas o todas las preguntas).

La fortaleza de este método radica en la posibilidad de ofrecer un reporte detallado en un formulario. El principal problema es la necesidad de un evaluador que proporcione las notas difusas en lugar de valores que dan los métodos tradicionales.

Valores esperados difusos[12]: Law propuso la evaluación del logro de un estudiante usando el enfoque del valor esperado difuso. Su meta fue construir un modelo estructural del sistema de calificaciones usando un modelo difuso. Las razones expuestas para tomar esta decisión se basaron en la fluctuación que sufre la nota del estudiante. Los exámenes pueden contener datos vagos y el método más común para asignar un valor al desempeño es con una letra (o un número como en la Argentina). Todas estas razones llevan a la necesidad del empleo de variables lingüísticas para la evaluación. Los pasos del algoritmo de Law comprenden:

1. Calcular valores esperados para las variables lingüísticas A, B, C, D y E , $E(\bar{A}), E(\bar{B}), E(\bar{C}), E(\bar{D})$ y $E(\bar{E})$ donde los valores difusos esperados para \bar{A} en R^n está definido por:

$$E(\bar{A}) = \frac{\int_{R^n} x \mu_A(x) dx}{\int_{R^n} \mu_A(x) f(x) dx}$$

donde $f(x)$ es la función de distribución de x en \bar{A}

2. Calcular la nueva puntuación P usando el método de defuzificación centroide $T = M \times (E(\bar{A}), E(\bar{B}), \dots, E(\bar{F}))$ donde M es una matriz de evaluación difusa (la cual contiene los valores de pertenencia difusos).

3. Calcular la puntuación final w con : $w = \sum_{j=1}^n w_j T_j$ donde w_j es el peso a cada T_j

El inconveniente de este método radica en su complejo proceso computacional, el cual dificulta la obtención de los valores del conjunto difuso. Además es difícil integrarlo en ambientes difusos.

Uso de los valores de la función de pertenencia difusa en unión con la teoría estadística[13]: Fourali usó este enfoque para la evaluación del conocimiento previo usando un portfolio

de evidencias. La razón principal del uso de este método proviene de concebir a los logros académicos como difusos. Asimismo, las decisiones son tomadas sobre evidencia ambigua ya que esta proviene de diferentes evaluadores con diferentes estándares.

El método calcula la puntuación final X , usando el valor esperado definido por:

$$X = \frac{\sum f(x_i)x_i}{\sum f(x_i)}$$

donde x_i es un valor entre 0 y 10 indicando el grado de competencia (0 indica extremadamente insatisfactorio y 10 muestra extremadamente satisfactorio) y $f(x_i)$ indica la frecuencia de x_i en valores difusos.

El algoritmo consta de:

1. Asignar un valor x_i a cada categoría de evidencia.
2. Calcular el valor esperado X basado en los valores $f(x_i)$. Este valor puede estar balanceado decidiendo un criterio sobre la evidencia (todas pueden ser igualmente importantes o proponer pesos diferentes).

Existen otros métodos similares al propuesto por Fourali. Por ejemplo, Chen y Lee [14] aplican los valores de la función de pertenencia a la teoría de la probabilidad. Su algoritmo establece:

1. Crear niveles y grados de satisfacción de acuerdo a niveles de satisfacción: *extremadamente bueno, muy-muy bueno, muy bueno, bueno, más o menos bueno, regular, más o menos malo, muy malo, muy-muy malo, extremadamente malo.*
2. Asignar notas difusas a Q_i (usando la planilla de notas difusas extendidas)
3. Calcular el grado de satisfacción para Q_i :

$$D(Q_i) = \frac{\sum y_i T(x_i)}{\sum y_i}$$

Donde y_i son los valores de pertenencia a cada pregunta y $T(x_i)$ es el grado de satisfacción para x_i .

4. Proponer la nota total calculada sobre varias preguntas:

$$\text{Nota total} = \sum T(Q_i) D(Q_i)$$

donde $T(Q_i)$ es la nota asignada para Q_i y $D(Q_i)$ es el grado de satisfacción para Q_i .

Este es un método sencillo y puede aplicarse para evaluar diferentes aspectos de las respuestas escritas como exactitud o claridad en las expresiones.

El modelo propuesto

Los métodos presentados de Fourali y Chen y Lee son bastantes simples y no usan mecanismos de inferencia difusa. Los métodos de Law y Biswas presentan cálculos más complejos, pero tampoco poseen inferencia difusa.

Teniendo en cuenta este aspecto de los métodos vistos, los autores de este trabajo consideran que la evaluación del logro de un estudiante tiene que presentar las siguientes características:

1. Usar las evaluaciones originales (notas, conceptos, etc.) como entradas y transformarlas en valores difusos en lugar de pedir al evaluador la asignación de valores difusos. Esto es muy importante para un STI porque adquiere información de la actividad del estudiante.
2. Usar mecanismos de inferencia en vez de solo manipular números difusos.
3. Poder usar diferentes niveles de evaluación sin necesidad de desarrollar otro método.

El modelo que se propone basado en [15] posee un modelo predictivo difuso que permite establecer *descripciones difusas* de los

alumnos así como *reglas lingüísticas difusas* para categorizarlos a fin de adaptar el aprendizaje individual de cada uno de ellos mediante un mecanismo de inferencia difusa.

Siguiendo estos lineamientos propuestos anteriormente, el modelo se basará en tres fuentes de evidencia mensurable:

1. Prueba DistSem. Esta prueba captura el conocimiento del estudiante sobre la distancia semántica entre conceptos. Posteriormente se mide la respuesta del estudiante con respecto a la solución de la misma prueba dada por un experto. Esta prueba es una aplicación sui generis del Análisis de Redes Sociales [16], donde los nodos a ser tratados son conceptos académicos propuestos por los docentes y las relaciones entre conceptos son capturadas en base a la similitud semántica estimada por los participantes. Este método permite capturar y colocar en una matriz, visualizar y comparar cuali y cuantitativamente, las redes semánticas de los participantes con un nivel de restricción aplicado a un número limitado de conceptos previamente definidos por el experto.
2. Pruebas tradicionales. Se usará la información brindada por asignaturas del plan de estudios de Ingeniería de la UNMDP.
3. Pruebas de opción múltiple.

Los resultados de estas pruebas, tomadas en distintos momentos de una cursada, se almacenan durante un año a fin de construir los datos de entrenamiento (ver figura 2). Por ejemplo, para el curso de Computación se guardan 11 atributos (3 pruebas DistSem, 3 parciales, 3 exámenes recuperatorios, 1 trabajo integrador, 1 nota final).

En base a los datos empíricos, se construye el Modelo predictivo conformado por funciones discretas predictivas. Por ejemplo, una función muy simple puede calcular el promedio de todos los alumnos en cada uno de los atributos.



Figura 2: Módulo del Razonador del Diagnóstico

Con esta función se pueden establecer dos grupos: el de los alumnos que *aprueban el curso* (los que sobrepasan los valores promedios) y el de los alumnos de *pobre desempeño* (los que quedan por debajo de esos valores y necesitarán apoyo en diversos niveles para terminar el curso). Los resultados de esta categorización forman las Descripciones difusas de los alumnos.

Estas descripciones dan las bases para interpretar las reglas lingüísticas difusas. Para construir estas reglas se necesita definir las *expresiones lingüísticas difusas*. La estructura de estas expresiones es:

Constructor lingüístico difuso	Concepto lingüístico
--------------------------------	----------------------

Por ejemplo, el concepto de desempeño *muy pobre* puede representar a alumnos que deberán ser atendidos especialmente por el sistema tutorial. Para declarar el concepto *muy pobre* use utiliza la siguiente expresión difusa:

<i>Muy</i>	<i>pobre</i>
------------	--------------

Pero el concepto lingüístico *pobre* puede poseer diversos constructores lingüísticos además de *muy*. Por ejemplo, puede definirse una secuencia de constructores de este tipo: *muy, bastante, moderadamente, poco y nada*.

Con las reglas difusas se categoriza a los estudiantes. Por ejemplo, el grupo de alumnos *conflictivo* puede responder a las siguientes reglas:

SI un estudiante tiene desempeño bastante pobre Y muy pasivo ENTONCES es bastante conflictivo

SI un estudiante tiene desempeño muy pobre Y moderadamente pasivo ENTONCES es muy conflictivo

Los Datos observados conservan los resultados de las pruebas tomadas a los nuevos alumnos a fin de categorizarse en el STI.

Este modelo puede usarse para evaluaciones diagnósticas (establecer, antes de la instrucción, las fortalezas, debilidades, conocimientos y destrezas de cada estudiante, para definir un perfil inicial), evaluación formativa (seguimiento del progreso del estudiante durante la enseñanza y aprendizaje, son “diagnósticos en transición” a fin de decidir cuál es el próximo paso en la enseñanza o cual es la respuesta a la necesidad creada en el), y evaluación final (tiene por finalidad determinar el nivel de logro alcanzado por un estudiante, a fin de llegar a un indicativo válido y confiable sobre las capacidades del estudiante). Los tres tipos de valoración pueden lograrse sin crear otro método.

Por ejemplo, las pruebas DistSem se ajustan muy bien para encontrar un diagnóstico inicial a partir de los conocimientos previos del alumno.

Conclusión

El modelo propuesto ha seguido los tres puntos considerados importantes en el diseño de un mecanismo de inferencia difusa dentro de un Sistema Tutorial Inteligente.

Principalmente, la propuesta emplea un modelo lingüístico difuso y da lugar a un

mecanismo de inferencia parecido a la forma en que los humanos toman decisiones.

Las categorías de los estudiantes consideradas útiles al aprendizaje adaptativo dentro del STI pueden incluir conceptos (además de *conflictivo*) tales como *colaborativo, dependiente, competitivo, atento, motivado, etc.* Si bien el modelo predictivo propuesto es sencillo, puede lograrse mayor riqueza y expresividad con funciones más elaboradas o usarse esquemas de mayor complejidad como árboles de decisión.

Actualmente se ha recolectado información de la actividad de los alumnos de dos asignaturas de la Facultad de Ingeniería correspondiente a los años 2007 y 2008. Se han definido los atributos para construir el modelo predictivo. Se están analizando varios modelos predictivos para avanzar hacia las descripciones difusas. Se espera obtener resultados hacia fines del 2009 y probar el sistema con los datos de las cursadas actuales.

Asimismo se está desarrollando un Módulo del Estudiante con las características propuestas en el STI Infosem en la Facultad de Ingeniería de la UNMDP [17].

Referencias

- [1] Burns, Capps. Foundation of Intelligent Tutoring Systems: An Introduction. En M. Polson & Richardson (eds). Foundation of Intelligent Tutoring Systems. Lawrence Erlbaum Associates Publishers USA. 1988.
- [2] Anderson John R. . The Expert Module. In Martha C. Polson & J.J. Richardson. Foundations of Intelligent Tutoring Systems. LEA. Hillsdale, New Jersey. 1988.
- [3] Sison, R. y Shimura, M. Student modeling and machine learning. International Journal of Artificial Intelligence in Education. 9, 128-158. 1988.
- [4] Hartley R., Paiva A. , Self J. Externalizing Learner Models. Proceedings de International Conference on Artificial Intelligence in Education, editado por J. Greer, pp. 509-516. Washington. AACE. 1995.

- [5] VanLehn K. Student modeling. En Foundations of Intelligent Tutoring Systems, eds.: Polson M.C. y Richardson J.J. Lawrence Erlbaum. 1988.
- [6] L. Zadeh. Fuzzy sets. Inf. and control. Vol 8, 338-353.1965.
- [7] L. Zadeh. Fuzzy logic. IEEE Computer. Vol 21(4), 83-93. 1988.
- [8] L. Zadeh. Fuzzy logic, neural networks and soft computing. Communications of the ACM. Vol 37(3), 77-84, 1994.
- [9] Zadeh L.A.. The concept of a linguistic variable and its application to aproximate reasoning . I-III Information Sci 8, , 199-250 y 301-357. 1975.
- [10] Dubois D. y Prade H. What are fuzzy rules and how to use them. Fuzzy sets and systems, 84:169-185. 1996.
- [11] Bitwas R. An application of fuzzy sets in students' evaluation. Fuzzy sets and systems. 74:187-194.1995.
- [12] Law C. Using fuzzy numbers in educational grading systems. Fuzzy sets and systems. Pp 311-323. 1996.
- [13] Fourali C. Fuzzy logic and the Quality of Assessment of Portfolios. Fuzzy sets and systems. 68:123-139. 1994.
- [14] Chen S. M., Lee C.H. New methods for Students' Evaluation using fuzzy sets. Fuzzy sets and systems. 104:209:218. 1999.
- [15] Nykanen O. Inducing Fuzzy Models for Student Classification. Educational Technology & Society. 9(2), 223-234. 2006.
- [16] Vivas J., Método Distsem: procedimiento para la evaluación de distancias semánticas. Revista Perspectivas en Psicología, 1, 56-61, 2004.
- [17] Huapaya C., G. Arona, F. Lizarralde, J. Vivas. InfoSem: Distancia Semántica entre conceptos como base de la Evaluación Cognitiva. En el libro "Las ciencias del Comportamiento en los albores del Siglo XXI". UNMDP-Conicet. , 405-411, 2005.