

Construcción de un modelo difuso optimizado del aprovechamiento académico de estudiantes en educación superior

Juan Carlos González-Castolo

Universidad de Guadalajara

jcgcastolo@cucea.udg.mx

Silvia Ramos-Cabral

Universidad de Guadalajara

silviarc@cualles.udg.mx

Sara Catalina Hernández Gallardo

Universidad de Guadalajara

shernand@cencar.udg.mx

Resumen

El presente trabajo muestra un método para construir un Modelo Difuso Optimizado del Aprovechamiento Académico (MDOAA) a partir de la prueba de aptitud y el promedio de calificaciones del primer semestre en estudiantes de educación superior. El MDOAA se basa en la teoría de Lógica Difusa (LD) debido a que por ser el Aprovechamiento Académico (AA) un fenómeno complejo, es más natural describirlo a través de consideraciones que se aproximen al razonamiento humano. El MDOAA se conforma por un conjunto de Conjuntos Difusos (CD) y reglas del tipo *if-then*. Para obtener los mejores CD que describan el AA, se utiliza un Algoritmo Genético (AG) llamado Fuzzy Sets find with Genetic Algorithm (FSGA), el cual contiene restricciones que imprimen características particulares y deseables en los CD.

Palabras clave: Educación superior, modelo optimizado, aprovechamiento escolar.

Introducción

Dentro de la política administrativa de toda institución de educación superior se exige la mejora de la eficiencia terminal, lo cual un resultado del AA. En su atención, existen trabajos que promueven soluciones con diferentes visiones; por ejemplo, la obtención del modelo del

fenómeno u objeto de estudio que en este caso es el AA. La obtención del modelo del AA ayuda a identificar con antelación algunos problemas que afectan la eficiencia terminal. Una vez identificados los problemas, se propicia la activación de los mecanismos de asistencia institucional que minimicen la reprobación, rezago o deserción de los estudiantes. Según la Real Academia Española (2001), un modelo es “un esquema teórico, generalmente en forma matemática, de un sistema o de una realidad compleja que se elabora para facilitar su comprensión y el estudio de su comportamiento”. De acuerdo con Shannon y Bernal (1988), el modelo se define como una representación de un objeto, sistema o incluso una idea. En este sentido, los modelos son utilizados en la comunicación, entretenimiento, la instrucción, la predicción y la experimentación (Tarifa, 2001). En el ámbito educativo se tiene que algunos modelos se utilizan para clasificar los estilos de aprendizaje (Durán y Costaguta, 2007) e identificar las debilidades de los estudiantes en fases iniciales de estudio (Lye et al., 2001). Otros enfoques se centran en utilizar los modelos de los alumnos para volver más eficientes los sistemas informáticos de asistencia estudiantil conocidos como tutores inteligentes (Larrañaga et al., 2004). Según Vizcaíno y Prieto (1998), el modelo del estudiante es también un modelo de simulación capaz de predecir los estados de sus componentes internos. Otros modelos se utilizan para predecir actitudes e intenciones de estudiantes en escenarios educativos relacionados con la medicina (Karamanlis et al., 2012). En lo que concierne al particular fenómeno de estudio, se tiene que existen modelos del AA que se encargan de evaluar el comportamiento interpersonal del profesor y así analizar su impacto en el aprovechamiento del estudiante al aprender una lengua extranjera (WeiyZhou, 2009). Es de notar que el AA del estudiante también se ve influenciado por las fuentes de información que le dan sentido a la creencia y certeza de la eficacia del profesor (Mohamadi y Asadzadeh, 2012). Lo anterior destaca que el AA es un concepto multifactorial pero que, por simplicidad del método descrito en este artículo, se hace corresponder con las calificaciones obtenidas por los estudiantes. Para construir el modelo de los fenómenos se requiere realizar una tarea que entraña procedimientos formales debido a la pretensión de reproducir el comportamiento de un objeto y/o sistema para su estudio, mejoramiento y/o control con el uso de recursos mecánicos, computacionales, matemáticos y/o lógicos. En el presente trabajo, el concepto de modelo se especifica como una serie de reglas y conjuntos difusos que reproducen el comportamiento de objeto de estudio, siendo este el AA. Para la construcción del modelo se hace uso de dos variables: 1) la prueba de aptitud académica (aptitude-test) y 2) el promedio del primer semestre (first-assessment); ambas procedentes de las bases de datos del centro universitario en estudio.

A continuación, se expone el marco teórico referente a los formalismos mencionados a lo largo del presente artículo que facilitará la explicación del método y experimento descritos más adelante. Después se plantea el método propuesto, se explica el experimento realizado y se muestran los resultados obtenidos. En el punto final, se dan las conclusiones. La exposición se hace a través de un discurso coloquial sin que por ello sea menos estricto el tratamiento de los conceptos.

Contenido

Lógica difusa. Colom y Ballester (2006) afirman que la LD o borrosa (fuzzy set en inglés) es una alternativa a la lógica basada en conjuntos discretos que pretende saber si alguien o algo forma parte de un conjunto determinado al cumplir con ciertas condiciones –un alumno es bueno o no–; mientras que, por el contrario, en la lógica difusa, se descubren grados diversos de pertenencia y no adscripciones basadas en todo o nada.

La LD corresponde al marco de la teoría de la posibilidad donde se pueden representar formalmente calificativos (etiquetas) cuya frontera de verdad es incierta; por ejemplo, frío, calor, alto, etcétera. Los Conjuntos Difusos (CD) son las representaciones gráficas de las relaciones que existen entre los calificativos y la verdad que entrañan para un valor específico de una variable que tratan de describirlos. Por ejemplo, para 18 grados centígrados en el medio ambiente, puede ser que el CD cuya etiqueta caliente tenga un grado de verdad de 0.01, y un CD con etiqueta templado tenga un grado de verdad de 0.8. Lo anterior indica que es más cierto que esté templado que caliente. La variable que tratan de describir los CD es la temperatura y la descripción se hace, por ejemplo, a través de los calificativos frío, templado y caliente. El grado de verdad varía entre cero y uno. Un conjunto difuso puede presentarse de diferentes formas, donde las más comunes son la triangular y trapezoidal. Se toma la primera por su sencillez y porque cumple con las características para describir el objeto de estudio (AA).

Algoritmos Genéticos. Los AG, introducidos por Holland (1975), consisten en una función matemática o una rutina que simula el proceso evolutivo de las especies, su objetivo es descubrir soluciones a problemas específicos de maximización o minimización. Arancibia y Soto (2006) señalan que el AG recibe como entrada una generación de posibles soluciones para el problema en cuestión, y arroja como salida los especímenes más aptos por generación (las

mejores soluciones), para que estos se reproduzcan y generen mejores descendientes, los que a su vez deberían tener características superiores que las generaciones pasadas.

El algoritmo general de un AG se describe en la Fig. 1. La población inicial es un conjunto de sujetos donde cada uno de ellos es una solución candidata para resolver un problema específico. Las generaciones son las veces que se generarán nuevas poblaciones. Dentro del ciclo reproductivo se seleccionan los sujetos al azar para posteriormente cruzar sus características (genes). En estos pasos se conserva la población primitiva y se añaden los sujetos cruzados obteniéndose una población temporal que es dos veces más grande que la población primitiva. La mutación de los sujetos se hace al azar de acuerdo a una probabilidad previamente establecida. Al final de este paso se tiene una población cuatro veces mayor que la población primitiva. La situación de que se haya incrementado la población es temporal y obedece al hecho de que en el paso de evaluación solo se seleccionaron los mejores sujetos entre la población primitiva, los cruzados y mutados. Los mejores sujetos son los que hacen converger el modelo a la descripción del fenómeno.

```
BEGIN /* Algoritmo Genético Simple */
  Generar una población inicial.
  Computar la función de evaluación de cada individuo.
  WHILE NOT Terminado DO
    BEGIN /* Producir nueva generación */
      FOR Tamaño población/2 DO
        BEGIN /*Ciclo Reproductivo */
          Seleccionar dos individuos de la anterior generación, para el cruce (probabilidad de
            selección proporcional a la función de evaluación del individuo).
          Cruzar con cierta probabilidad los dos individuos obteniendo dos descendientes.
          Mutar los dos descendientes con cierta probabilidad.
          Computar la función de evaluación de los dos descendientes mutados.
          Insertar los dos descendientes mutados en la nueva generación.
        END
      IF la población ha convergido THEN
        Terminado := TRUE
    END
  END
END
```

Fig. 1. Pseudocódigo del Algoritmo Genético Simple.

Nota: separar las palabras dos descendientes

Función de Medición de Desempeño. Para evaluar y/o hacer la medición del nivel de acercamiento a la descripción del fenómeno se utiliza una ecuación que mide la distancia que existe entre la curva del modelo y los puntos de análisis. Se utiliza la Magnitud del Error Relativo (MER) de Kitchenham (2001) para evaluar la estimación del aprovechamiento:

$$MER = \frac{|\text{actual_firts-assessment} - \text{predicted_firts-assessment}|}{\text{predicted_firts-assessment}} \quad (1)$$

El acumulado de MER sobre múltiples observaciones es calculado a través de MMER, donde:

$$MMER = \frac{1}{N} \sum_{i=1}^N MER_i \quad (2)$$

Método

Se establece la obtención del MDOAA en los siguientes pasos: 1) Obtención de dos grupos de datos que se utilizan para obtener y verificar el MDOAA, respectivamente; 2) Establecimiento de un conjunto de CD que ligados con las reglas, forman los modelos difusos primarios; 3) Proceso de optimización de los modelos difusos primarios donde se modifican y seleccionan los CD asociados a las reglas un determinado número de veces para obtener el MDOAA; 4) Verificación del MDOAA.

Paso 1: Los datos de análisis son en los rubros: 1) la prueba de aptitud (aptitude-test) que se aplica a los estudiantes de nuevo ingreso y 2) el promedio de las calificaciones del primer semestre (first-assessment) y que son facilitados por el Centro Universitario Participante (CUP). Se hace notar que solo se trabaja con datos de alumnos que tienen información en los dos rubros mencionados. El rubro first-assessment se hace coincidir con el concepto de AA, de tal forma que a mayor puntaje en las calificaciones se tiene un mayor AA y viceversa. Se cuentan con dos grupos de datos de estudiantes que ingresaron en diferentes periodos. Con el primer grupo de datos se obtiene el MDOAA y con el segundo se verifica que dicho MDOAA cumpla con la representación del fenómeno de estudio.

Paso 2: Se establece un conjunto de modelos difusos primarios en los cuales cada uno consta de tres reglas del tipo if-then (R_1, R_2, R_3) y un CD asociado al antecedente (CDA) y consecuente (CDC) de cada regla ($\{CDA_1, CDC_1\} \subset R_1, \{CDA_2, CDC_2\} \subset R_2, \{CDA_3, CDC_3\} \subset R_3$). Los CD utilizados deben cumplir una jerarquía que establece $CDA_1 \leq CDA_2 \leq CDA_3$ y $CDC_1 \leq CDC_2 \leq CDC_3$.

Paso 3: Cada modelo difuso del Paso 2 describe el AA en mayor o menor grado. El proceso de optimización consiste en generar un nuevo conjunto de modelos a partir de los que se tienen e ir seleccionando los que en mayor grado describan el AA. Después de un determinado número de veces donde se hace la selección, se obtendrá el mejor modelo llamado MDOAA. Para realizar la optimización se utiliza un AG llamado FSGA, el cual modifica los conjuntos CDA_1 , CDC_1 , CDA_2 , CDC_2 , CDA_3 , CDC_3 y cumple con la jerarquía establecida en el paso anterior.

Paso 4: Para validar el MDOAA se utiliza el segundo grupo de datos. Se verifica que el MMER utilizando el MDOAA sobre el primer y segundo grupo de datos, sea muy próximo. El criterio del valor de proximidad se establece por un experto.

Experimento

Para el diseño del MDOAA, se tienen los datos que resultan del análisis de las bases de datos del CUP y que se muestran en la fig. 2. Los puntos oscuros son datos que se utilizan para construir el modelo y los claros son para validar dicho modelo. La gráfica relaciona los resultados de la prueba de aptitud y las calificaciones del primer semestre. Se hace notar que pueden existir valores atípicos que no se discriminaron para obtener ni validar el modelo, puesto que lo importante en este artículo, es mostrar la propuesta del modelado de aprovechamiento académico con el uso de los paradigmas de la inteligencia artificial. Los valores atípicos pueden ser originados por diversas situaciones que no se analizan en este trabajo.

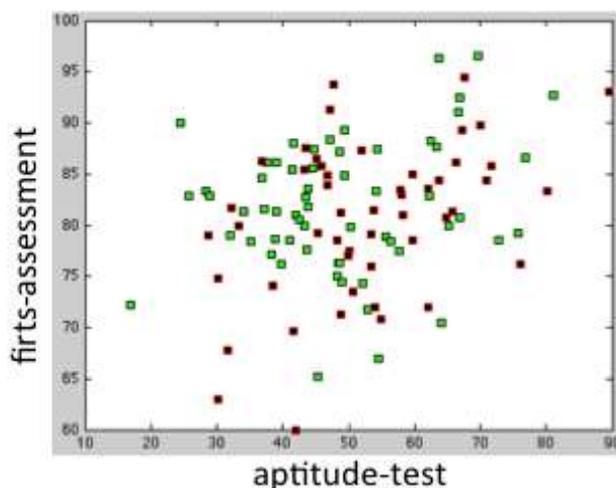


Fig. 2. Población de análisis.

Al realizar un razonamiento natural, es factible inferir que un estudiante con menor puntaje en la prueba de aptitud tendrá, después de un semestre, una baja calificación. Un estudiante que

tiene un puntaje promedio obtendrá una calificación regular y un estudiante que tiene un puntaje elevado, obtendrá una alta calificación. En este punto cabe señalar que existen variables que inciden sobre un resultado de una prueba de aptitud tal como el estado de ánimo del estudiante, el medio ambiente, la disposición de un aplicador e incluso si comió el estudiante. El análisis de las variables mencionadas está fuera del propósito del presente trabajo. Se trabajan sobre los datos académicos porque es la información básica con la que se dispone en la universidad. Para la obtención del MDOAA se realiza un razonamiento natural que se establece por las reglas lógicas:

1. El estudiante con puntaje pequeño (*small*) tendrá una calificación baja (*low*).
2. El estudiante con puntaje mediano (*medium*) tendrá una calificación regular (*average*).
3. El estudiante con puntaje alto (*big*) tendrá una calificación elevada (*high*).

La representación formal de las reglas queda como sigue:

1. *if small then low*
2. *if medium then average*
3. *if big then high*

Donde las etiquetas *small*, *medium* y *big* son los antecedentes de cada una de las reglas; y *low*, *average* y *high* los consecuentes. A cada una de las etiquetas se le asocia un CD de forma triangular, dicha forma se caracteriza por ser simple y cumple con los requerimientos de representación en el modelo. Para la definición de cada CD \tilde{a} son necesarios tres parámetros, esto es: $\tilde{a}=(w_1, w_2, w_3)$. Los CD que están como antecedentes representan los valores de los calificativos sobre la prueba de aptitud y los CD que están como consecuentes representan calificativos de las calificaciones obtenidas. Las etiquetas que se utilizan en el modelo para los CD se muestran en la fig. 3.

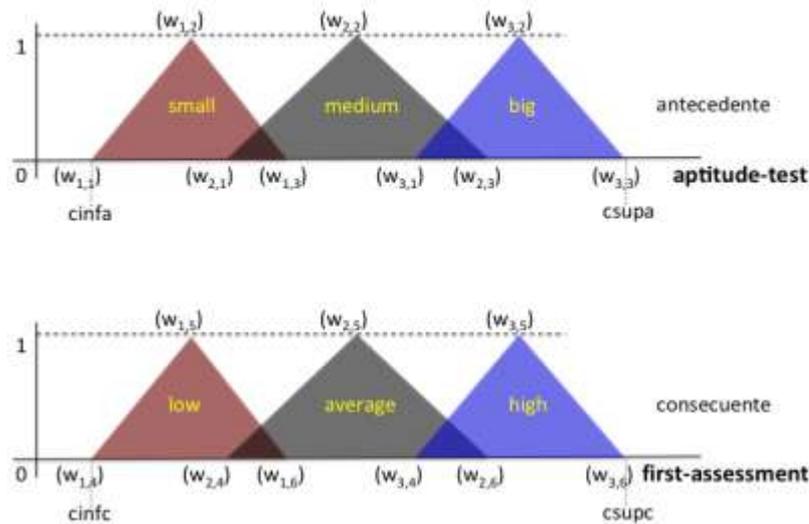


Fig. 3. Característica de un sujeto o solución candidata.

Un conjunto de CD asociados a las reglas, es un sujeto dentro del AG. Un sujeto es una solución candidata. Formalmente se define un sujeto como:

$$M = (w_{r,1}, w_{r,2}, w_{r,3}, w_{r,4}, w_{r,5}, w_{r,6}) \mid r = 1, 2, 3 \quad (3)$$

Donde el índice r se corresponde con cada una de las reglas, de tal manera que para $r=1$ se tiene que $w_{1,1}, w_{1,2}, w_{1,3}$ describe el CD *small*, $w_{1,4}, w_{1,5}, w_{1,6}$ describe el CD *low*, y así sucesivamente para el resto de los CD asociados a las etiquetas de las reglas. El esquema que se trabaja para el cruce de características de los *sujetos* dentro del FSGA es:

$$M = [\tilde{a}_A, \tilde{a}_C] \quad (4)$$

Los genes se modifican de forma aleatoria para producir un nuevo individuo y están asociados con M , Ec. (3). Se trabajó con un tamaño de *población* (número de *sujetos*) de ocho aunque puede ser cualquier cantidad. Las *generaciones* (número de veces que la población se renueva) fueron cien aunque el número queda a elección de la rapidez de la convergencia. Los CD se forman bajo ciertas restricciones que se corresponden con el hecho de que el CD *small* (*low*) representa un calificación menor que el CD *medium* (*average*) y este último a su vez, representa un calificación menor que *big* (*high*). Cabe aclarar que el AG admite carecer de las restricciones sobre los CD y así logra encontrar soluciones que salen del esquema que redefinió donde puede suceder, por ejemplo, que el CD *big* represente valores menores que el CD *small*.

El procedimiento del FSGA se describe en los siguientes pasos:

1. Se crea una población inicial (un número predefinido de sujetos).
2. El punto de paro del algoritmo está determinado por el número de generaciones predefinidas.
3. Se ordenan aleatoriamente los sujetos.
4. Se incrementa la *población* inicial (duplica) con sujetos donde se hace cruce de características (conjuntos de genes) entre cada par de sujetos de tal manera que los $CD_{\tilde{c}}$ del primer sujeto pasan a los $CD_{\tilde{c}}$ del siguiente *sujeto* y viceversa, Ec. (4).
5. Se incrementa la población del punto cuatro (se cuadriplica la población inicial) con sujetos que mutan aleatoriamente sus características en correspondencia con las etiquetas de los CD, de tal manera que un sujeto puede tener un nuevo CD asociado a *small* o *low* o... o *high*.
6. Se evalúan los sujetos (soluciones candidatas) y se eligen solo los mejores sujetos que cubran el tamaño de la población.
7. Se repiten los pasos 3,...,6 hasta que el paso dos se cumple.

El algoritmo FSGA se ejecutó, corrió con una evolución fijada en 500 y una población de 100 individuos. La probabilidad de mutación es de 0.3. En los resultados se obtiene un sujeto (mejor solución) con las siguientes características:

$$\tilde{S} = \begin{matrix} \hat{e} \\ \hat{e} \\ \hat{e} \\ \hat{e} \end{matrix} \begin{matrix} -11.0858 & 11.0992 & 14.3318 & 0 & 14.9809 & 62.8801 \\ -22.8325 & 61.7106 & 63.3096 & 59.2192 & 79.5044 & 82.4685 \\ -13.8496 & 80.8389 & 115.2792 & 65.8136 & 96.2860 & 100.0000 \end{matrix} \begin{matrix} \hat{u} \\ \hat{u} \\ \hat{u} \\ \hat{u} \end{matrix} \quad (3)$$

Se aclara que la solución no es única, lo que se traduce en que para otro experimento se obtiene otro sujeto con características diferentes que cumpla con el criterio de mejor aproximación en la descripción de la relación *aptitude-test* y *firts-assessment*. Los CD correspondientes con \tilde{S} se muestran en la Fig. 4.

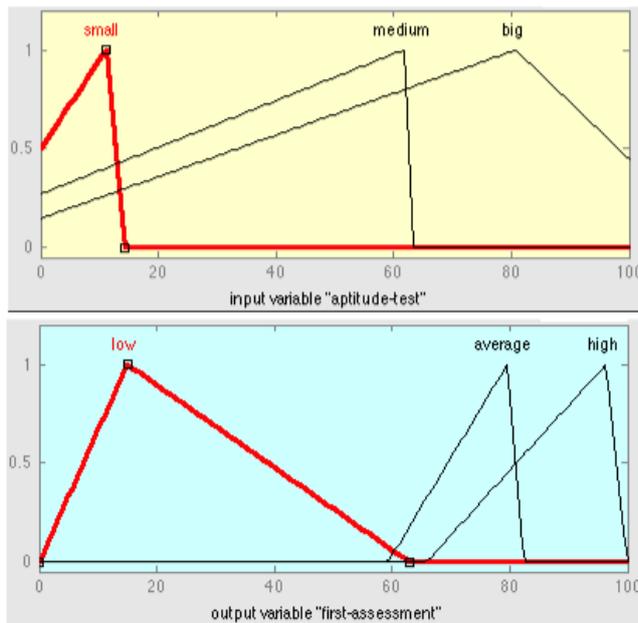


Fig. 4. Sujeto (mejor solución).

Utilizando el método del centroide para la defuzzificación de la información, se obtiene la curva mostrada en la Fig. 5 y que se corresponde con la representación del MDOAA obtenido.

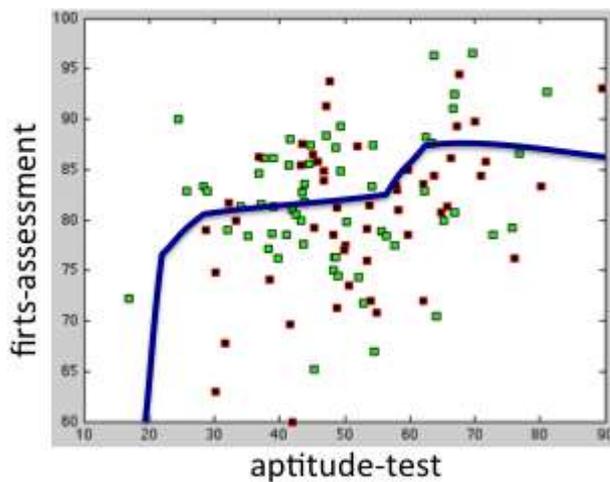


Fig.5. Representación del modelo obtenido.

Se observa que el MDOAA trata de hacer la representación de los datos haciéndose notorio que al final de la curva hay un descenso. Lo anterior no es crítico en el método porque no existen datos de análisis cuando decrece la curva. Se afirma que el modelo válido existe para (20,80) aproximadamente, según se aprecia en la fig. 5. El error relativo, Ec. (2), se obtiene con los datos de construcción y los de validación son $MMER=0.0579$ y $MMER_{vali}=0.0671$, respectivamente. Como el error es muy pequeño se establece que el modelo es aceptable.

Conclusiones

Con este trabajo se expone un método para obtener un modelo formal del AA de estudiantes de educación superior. El modelo obtenido es llamado MDOAA, el cual resulta atractivo porque se maneja con reglas que se aproximan al razonamiento humano y que por ende resultan fáciles de trabajar por diversas instancias que manejen, por ejemplo: la acción tutorial, la atención presupuestal, la asistencia psicológica, etcétera. El método para la construcción del MDOAA sirve como base para obtener una representación formal que permita predecir el AA de los estudiantes. Para tener un MDOAA confiable que sirva en la predicción del AA es necesario incrementar los datos de análisis. Por ejemplo, incrementar el número de variables que procese el FSGA de tal manera que se involucren variables psicológicas, promedio de la escuela de procedencia y prueba de aptitud. Se prevee enriquecer el MDOAA si se toman en cuenta los datos generados a través del uso de alguna plataforma virtual como Moodle. Nótese que solo se habla de información académica porque es únicamente esa con la que cuenta una institución de educación superior. El modelo es aceptable y con mayor información se conseguirá refinar y/o adaptar según sea el ambiente en el cual opere. El FSGA admite ser incluido como una subrutina de cálculo dentro de un programa especializado en detectar situaciones prioritarias de atención en los estudiantes. Finalmente, si con la aplicación de MDOAA se obtiene un pronóstico de bajas calificaciones entonces la acción tutorial puede focalizarse en la atención del problema.

Bibliografía

- Arancibia V, N., & Soto A, P. (2006). *Técnicas avanzadas para la predicción de la variación del precio de la acción de BHP Billiton*. Tesis doctoral, Universidad de Chile.
- Colom Cañellas, A. J., & Ballester Brage, L. (2006). Lógica difusa: una nueva epistemología para las Ciencias de la Educación. *Revista de educación*, (340), 995-1008.
- Durán, E. B., & Costaguta, R. N. (2007). Minería de datos para descubrir estilos de aprendizaje. *Revista Iberoamericana de Educación*, 42(2), 6.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems*. Ann Arbor, MI: University of Michigan Press.

- Karamanlis, D. A., Tzitzis, P. M., Bratsas, C. A., & Bamidis, P. D. (2012). Personal health records in the preclinical medical curriculum: modeling student responses in a simple educational environment utilizing Google Health. *BMC Medical Education*, 12(1), 88.
- Kitchenham, B.A., MacDonell, S.G., Pickard, L.M. & Shepperd, M.J. (2001). What Accuracy Statistics Really Measure. *IEE Proceeding Software*.
- Larrañaga, M., Elorriaga, J. A., Rueda, U., & Arruarte, A. (2004). Modelado de grupos en actividades de aprendizaje basado en mapas conceptuales. *Inteligencia artificial: Revista Iberoamericana de Inteligencia Artificial*, 8(24), 131-148.
- Lye, C. T., Ng, L. N., Hassan, M. D., Goh, W. W., Law, C. Y., & Ismail, N. (2010). Predicting Pre-university Student's Mathematics Achievement. *Procedia-Social and Behavioral Sciences*, 8, 299-306.
- Mohamadi, F. S., & Asadzadeh, H. (2012). Testing the mediating role of teachers' self-efficacy beliefs in the relationship between sources of efficacy information and students achievement. *Asia Pacific Education Review*, 13(3), 427-433.
- Parisi, F. (2004). Modelos de algoritmos genéticos y redes neuronales en la predicción del signo de variación del IPSA.
- Real Academia Española. (2001). *Diccionario de la lengua española* (22.aed.) Consultado en <http://www.rae.es/rae.html>
- Shannon, R. E., & Bernal, F. A. (1988). *Simulación de sistemas: Diseño, Desarrollo e implantación*. Trillas. México.
- Tarifa, E. (2001). Teoría de Modelos y Simulación. *Facultad de Ingeniería, Universidad de Jujuy*.
- Vizcaíno, A., Olivas, J. A., & Prieto, M. (1998). Modelos del estudiante en entornos de aprendizaje colaborativo. *TSIE98*.

Wei, M., den Brok, P., & Zhou, Y. (2009). Teacher interpersonal behaviour and student achievement in English as a Foreign Language classrooms in China. *Learning Environments Research, 12*(3), 157-174.