

Este documento ha sido descargado de:
This document was downloaded from:

Núlan

**Portal *de* Promoción y Difusión
Pública *del* Conocimiento
Académico y Científico**

<http://nulan.mdp.edu.ar> :: @NulanFCEyS

+info <http://nulan.mdp.edu.ar/115/>

Las Redes Neuronales Artificiales como elementos del Sistema de Soporte a las Decisiones en la Administración Universitaria.¹

Artificial Neural Networks as tools of the Decision Support System in the University Management.

Lucía Isabel Passoni²

RESUMEN/SUMMARY

El trabajo presenta una propuesta metodológica novel para el diseño de un sistema de ayuda a las decisiones en el área académica de una institución universitaria. Esencialmente propone un proceso de Minería de Datos que utiliza redes neuronales artificiales del tipo autoorganizadas como herramientas para el análisis exploratorio de datos multidimensionales. El experimento se realizó sobre una base de datos de alumnos de grado pertenecientes a la carrera de Ingeniería Electrónica de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata. El proceso generó la identificación de grupos que presentaban diferentes patrones de evolución en la carrera. A partir de la visualización de los agrupamientos se realizó la interpretación y explicación del fenómeno, obteniéndose elementos de juicio relevantes que facilitan el proceso de toma de decisiones en el área académica.

This paper presents a novel methodological proposal for a decision making system design within the academic area of the institution and a Data Mining process that utilizes artificial neural networks, specifically auto-organized maps, as a tool

¹ Resumen de tesis de maestría en Gestión Universitaria de la Facultad de Ciencias Económicas y Sociales de la Universidad Nacional de Mar del Plata.

² lpassoni@fi.mdp.edu.ar

for the exploratory analysis of multidimensional data. The experiment was carried out on a university degree students data base, who belonged to the career of Electronic Engineering of the Facultad de Ingeniería de la Universidad Nacional de Mar del Plata. Case groups with different study evolutions patterns were identified. The interpretation and phenomenon explanation were attained from the visualization of the clusters, getting to relevant trial elements that facilitate the decision making process in the academic area.

PALABRAS CLAVES / KEYWORDS

Gestión universitaria, toma de decisiones, minería de datos, redes neuronales artificiales.

University management, decision making, data mining, artificial neural networks.

INTRODUCCIÓN

Esta tesis tiene como objetivo presentar una propuesta metodológica novel que se inserte en el proceso de toma de decisiones en el ámbito de la gestión universitaria.

El marco conceptual de esta propuesta es multidisciplinario dado que contiene elementos de diversos campos; así, aborda la Teoría de la Administración mediante la que fundamenta su necesidad y utiliza para su solución elementos de la Teoría de la Información, de Inteligencia Computacional, de Estadística y de Informática.

La formación y experiencia de la autora en estas áreas, docente e investigadora del Laboratorio de Bioingeniería de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata, ha permitido esta visión del problema.

El tema general que aborda es el Diseño de un proceso de Ayuda a las Decisiones, basado en Minería de Datos y el empleo de las Redes Neuronales Artificiales como técnica de análisis de datos multidimensionales.

Si bien se han realizado experiencias en otros campos de aplicación, la originalidad de la propuesta radica en la práctica de esta metodología en el área de la Administración de Instituciones de Educación Superior.

La actualidad de la temática es relevante, como lo destaca una edición especial del *Transactions on Neural Networks* de junio de 2000 (año de presentación del documento de la tesis para su evaluación) dedicada al

Descubrimiento del Conocimiento. En esta publicación se analiza la potencialidad de las Redes Neuronales como elementos de la Minería de Datos, (Bengio, *et al.*, 2000).

MOTIVACIÓN

Las nuevas tendencias en administración de instituciones de educación superior han propiciado la incorporación de técnicas de gestión “importadas” del mundo empresarial con el fin de elevar la eficiencia y la efectividad de su desempeño. Es así como nuevas tecnologías organizacionales tales como la calidad total, la planificación estratégica y la gerencia por objetivos han sido incorporadas en forma reciente en las instituciones universitarias norteamericanas, (Fanelli, 1998). Si bien existen ciertos factores de especificidad de la gestión pública que la diferencia del mundo empresarial, sin lugar a dudas las técnicas gerenciales aportan herramientas adecuadas al reto de la modernización de las administraciones públicas, (Andreu, Ricarte y Valor, 1994). El modelo de decisión racional que subyace en las técnicas de gestión empresarial sitúa su ámbito de aplicación en la actuación de las organizaciones públicas individualmente consideradas y en su funcionamiento interno.

En el grupo de las técnicas específicas de apoyo al ciclo de gestión de los objetivos organizativos globales (planificación-ejecución-control) se hallan entre otras las técnicas de gestión de los sistemas de información, y las de control de gestión y evaluación de resultados. Según Andreu, *et al.*, 1994, se entiende como Sistema de Información al “conjunto formal; de procesos que, operando sobre una colección de datos estructurada de acuerdo con las necesidades de la empresa, recopila, elabora y distribuye la información necesaria para la operación de dicha empresa y para las actividades de dirección y control correspondientes, apoyando, al menos en parte, los procesos de toma de decisiones necesarias para desempeñar las funciones de negocio de la empresa de acuerdo con su estrategia”.

Si bien existen algunas, las técnicas enunciadas son factibles de utilizar en la gestión administrativa de instituciones universitarias, tanto en la visión que comprende a la totalidad del sistema de educación superior, como así también aquella que considera a las instituciones en forma individual, son inexistentes las aplicaciones en el área de sistemas de apoyo a la toma de decisiones.

Esta problemática se evidencia en las universidades cuando se intenta abordar cuestiones relacionadas esencialmente con el financiamiento y la

planificación. El diseño del presupuesto institucional, la presentación de proyectos con fines específicos, la creación de nuevas carreras, son decisiones que deben ser sustentadas en el conocimiento del estado del sistema.

A partir de las últimas tendencias en la ciencia de la administración, la gestión universitaria puede ser abordada desde la Gerencia del Conocimiento (“*Knowledge Managment*”). Este es uno de los temas cruciales del proceso de administración dentro de las organizaciones y una fuente principal de ventaja competitiva. Si bien es difícil de definir, se la puede considerar como a una disciplina con dos aspectos primarios:

1. Trata el conocimiento como un componente vital de la organización que se refleja en la estrategia, en la política y la práctica en todos los niveles.
2. Conecta en forma directa los resultados de la evaluación de la inteligencia de la empresa con sus resultados positivos.

En la práctica, la Gerencia del Conocimiento puede definirse como 'la adquisición, el uso y el compartir el conocimiento dentro de la organización, que incluye procesos de aprendizaje y sistemas de información gerencial'.

Teóricos del gerenciamiento tales como Peter Drucker, (Drucker, 1993), y Peter Senge, (Senge, 1990) han contribuido a la evolución del Gerenciamiento del Conocimiento. Drucker ha enfatizado la creciente importancia de la información y del conocimiento explícito como recursos organizacionales, mientras que Senge ha abordado una dimensión cultural de la gerencia, considerando a las empresas e instituciones como organizaciones que aprenden (“*learning organizations*”).

La Gerencia del Conocimiento es un dominio que atraviesa disciplinas entre las que se encuentran: la ciencia cognitiva, los sistemas expertos, la inteligencia artificial, las redes neuronales, el trabajo en grupos apoyado por computadoras, la ciencia de la información, las redes semánticas e incluye los sistemas de soporte a las decisiones.

Nos encontramos en una etapa en la cual la tecnología provoca cambios en la estructura y funcionamiento de todas las organizaciones. No obstante lo difundido de su utilización para las tareas operativas, este tipo de herramientas permanece subutilizado por los líderes de las organizaciones en los procesos de toma de decisión (Mc. Nurlin y Sprague, 1998).

MATERIALES Y MÉTODOS

Minería de Datos

La Minería de Datos (*Data Mining*) es un proceso que, mediante el descubrimiento y cuantificación de relaciones predictivas en los datos, permite transformar la información disponible en conocimiento útil para la organización. Dentro de los sistemas de soporte a las decisiones, hallamos la Minería de Datos como una herramienta poderosa. La minería de datos es una idea basada en una simple analogía. El crecimiento de los almacenes de datos ha creado montañas de datos, que representan un recurso de gran valor para la organización. No obstante para extraer lo valioso de la montaña se debe excavar, o practicar la minería, para llegar a las 'pepitas' de metal precios, en nuestro caso el conocimiento, (Fayyad *et al.*, 1996).

En todas las organizaciones, aun en la universidad como así también en los ministerios del gobierno, las bases de datos son construidas con gran entusiasmo; no obstante, no existe consenso acerca del significado de la minería de datos o de lo que dicho proceso conlleva, o bien de cuál es el resultado del proceso, ni de qué herramientas se vale.

Una de las definiciones aceptables de la minería de datos afirma que es una metodología de análisis de datos tradicional enriquecida con las técnicas más avanzadas aplicadas al descubrimiento de patrones desconocidos. Se trata de un concepto de explotación de naturaleza radicalmente distinta de la de los sistemas de información de gestión, dado que no se basa en indicadores de gestión o en información altamente agregada, sino en la información de detalle contenida en la base de datos. Constituye, por tanto, una de las vías clave de explotación del "Data Warehouse", dado que es este su entorno natural de trabajo.

La minería de datos, consistente en la extracción de información oculta y predecible de grandes bases de datos, es una poderosa tecnología con gran potencial para ayudar a las compañías a concentrarse en la información más importante de sus bases de información, (Fayyad *et al.*, 1997). Al Descubrimiento de Conocimiento en Bases de Datos (*Knowledge Databases Discovery KDD*) se lo define como al Proceso de extracción no trivial para identificar patrones que sean válidos, novedosos, potencialmente útiles y entendibles, a partir de datos, (Piatetsky-Shapiro, Frawley, 1991).

La combinación de medidas de utilidad, novedad, simplicidad y validez sirve para establecer qué tan interesantes pueden ser los patrones. En este sentido, se puede afirmar que un patrón representa conocimiento si su

medida de interesante rebasa un cierto umbral, lo cual está basado únicamente en medidas definidas por el usuario. El proceso de KDD consiste en usar métodos de minería de datos (algoritmos) para extraer (identificar) lo que se considera como conocimiento de acuerdo con la especificación de ciertos parámetros y el uso de una base de datos junto con sus pre-procesamientos, muestreo y transformaciones.

Para obtener información provechosa que no está representada explícitamente en los datos, la minería de datos combina técnicas de inteligencia artificial, análisis estadístico, bases de datos y visualización gráfica.

Las técnicas más comúnmente usadas en minería de datos son las redes neuronales artificiales, los árboles de decisión, algoritmos genéticos y la regla de inducción, (Fayyad, *et al.*, 1996b).

REDES NEURONALES ARTIFICIALES.

Como herramientas de la Minería de Datos, las Redes Neuronales Artificiales han ganado una creciente importancia. Algunas definiciones sobre estos algoritmos: para Simon Haykin, (Haykin, 1994) "Una red neuronal es un procesamiento distribuido masivamente paralelo que tiene una tendencia natural para almacenar conocimiento empírico y hacerlo disponible para el uso. Recuerda el cerebro en dos aspectos:

1. El conocimiento se adquiere por la red a través de un proceso de aprendizaje.
2. Las conexiones entre neuronas se conocen como pesos sinápticos y se usan para almacenar el conocimiento.

Para poder aprender, las redes neuronales se sirven de un **algoritmo de aprendizaje**. Estos algoritmos están formados por un conjunto de reglas que permiten a la red neuronal aprender (a partir de los datos que se le suministran), mediante la modificación de los pesos sinápticos de las conexiones entre las neuronas (recordar que el umbral de cada neurona se modificará como si fuese un peso sináptico más). Generalmente, los datos que se usan para entrenar la red se le suministran de manera aleatoria y secuencial.

Los tipos de aprendizaje pueden dividirse básicamente en tres, de acuerdo con como esté guiado tal aprendizaje:

- **Aprendizaje supervisado:** se introducen unos valores de entrada a la red

- y los valores de salida generados por esta se **comparan** con los valores de salida correctos. Si hay **diferencias**, se **ajusta** la red en consecuencia.
- **Aprendizaje de refuerzo:** se introducen valores de entrada y lo único que se le indica a la red es si las salidas que ha generado son **correctas** o **incorrectas**.
- **Aprendizaje no supervisado:** no existe ningún tipo de **guía**. De esta manera lo único que puede hacer la red es reconocer **patrones** en los datos de entrada y crear **categorías** a partir de estos patrones. Así, cuando se de entrada a algún dato, después del entrenamiento, la red será capaz de clasificarlo e indicará en qué categoría lo ha clasificado.

El procedimiento usado para realizar el proceso de aprendizaje es llamado **algoritmo de aprendizaje**, su función es modificar los pesos de la red de modo tal de obtener los objetivos deseados.

REDES NEURONALES AUTO-ORGANIZADAS

Este grupo de redes neuronales se caracteriza porque en su entrenamiento no se presentan las salidas, objetivo que se desean asociar a cada patrón de entrada. La red, a partir de un proceso de auto-organización, proporcionará cierto resultado, el cual será reflejo de las relaciones de similitud existentes entre dichos patrones de entrada. La principal aplicación de estos modelos será la realización de agrupamiento de patrones, visualización de datos y representación de densidades de probabilidad.

A diferencia de lo que sucede en el aprendizaje supervisado, en el no supervisado (auto-organizado) no existe ningún maestro externo que indique si la red neuronal está operando correcta o incorrectamente, pues no se dispone de ninguna salida, objetivo hacia la cual la red neuronal deba tender.

LAS REDES AUTO-ORGANIZADAS CREADAS POR KOHONEN.

Tuvo Kohonen presentó en 1982 un modelo de red neuronal con capacidad para formar mapas de características de manera similar a como ocurre en el cerebro. El objetivo de Kohonen era demostrar que un estímulo externo (información de entrada) por sí solo, suponiendo una estructura propia y una descripción funcional del comportamiento de la red, era suficiente para forzar la formación de mapas, (Kohonen, 1990; Kohonen,

1993; Vesanto, 1999).

Las redes presentadas por Kohonen pertenecen a la categoría de las redes competitivas o mapas de autoorganización, es decir, aprendizaje no supervisado. Poseen una arquitectura de dos capas (una de entrada y la segunda de salida), y presenta funciones de activación lineales y flujo de información unidireccional

Las unidades de entrada reciben datos, vectores de patrones normalizados; se normalizan asimismo los pesos de las conexiones con la capa de salida. Tras el aprendizaje de la red, cada patrón de entrada activará una única unidad de salida.

El objetivo de este tipo de redes es clasificar los patrones de entrada en grupos de características similares, de manera que cada grupo activará siempre la(s) misma(s) salida(s). Cada grupo de entradas queda representado en los pesos de las conexiones de la unidad de salida que activa. La unidad de salida ganadora para cada grupo de entradas no se conoce previamente; es necesario averiguarla después de entrenada la red.

En la arquitectura de la versión original del modelo Kohonen no existen conexiones hacia atrás. Se trata de una de las N neuronas de entrada y M de salida. Cada una de las N neuronas de entrada se conecta a las M de salida mediante conexiones hacia adelante.

Entre las neuronas de la capa de salida, puede decirse que existen conexiones laterales de inhibición (peso negativo) implícitas, pues aunque no estén conectadas, cada una de las neuronas va a tener cierta influencia sobre sus vecinas. El valor que se asigne a los pesos de las conexiones hacia adelante entre las capas de entrada y salida durante el proceso de aprendizaje de la red va a depender precisamente de esta interacción lateral.

La influencia que una neurona ejerce sobre las demás es función de la distancia entre ellas y es muy pequeña cuando están muy alejadas.

MÉTODOS DE VISUALIZACIÓN DE INFORMACIÓN BASADOS EN MAPAS AUTO-ORGANIZATIVOS

La visualización es considerada un proceso muy importante en la Minería de Datos, ya que es considerada un proceso interactivo que requiere que la intuición y el conocimiento previo del operador se conjuguen con la eficiencia provista por las nuevas tecnologías computacionales, (Vesanto, 1999).

El mapa auto-organizativo o SOM ha probado ser una herramienta valiosa en Minería de Datos y KDD en aplicaciones de análisis de datos financieros. Se ha aplicado en forma exitosa en problemas de ingeniería tales como reconocimiento de patrones, análisis de imágenes, monitoreo y diagnóstico de fallas. El SOM tiene ciertas características que lo hacen un método útil para la Minería de Datos. Lleva a cabo un mapeo que reduce la dimensionalidad, en forma ordenada, del conjunto de entrenamiento. El mapeo es coherente con la función densidad de probabilidad de los datos y presenta un comportamiento robusto con los datos perdidos. Es sencillo de explicar y, lo que es aún más importante, de visualización fácil. La visualización de datos complejos y multidimensionales es, en efecto, una de las principales áreas de aplicación del SOM. A partir de experiencias, se puede inferir el éxito de la aplicación de los mapas SOM en otras áreas de la ciencia; ejemplo de ello es el reconocimiento de patrones de señales biomédicas, (Passoni *et al.*, 1995) Uno de los grandes retos de la minería de datos es la organización y rescate de documentos desde grandes archivos, (Joutsiniemi, Kaski y Larsen, 1995), (Kaski y Kohonen, 1996), (Kaski *et al.*, 1996).

RESULTADOS

Con el fin de experimentar técnicas de minería de datos, se propone la utilización de las bases de datos académicos de los alumnos de la carrera de Ingeniería Electrónica, inscriptos en el Plan 1992. Si bien el plan de estudios vigente a la fecha de realización del experimento es el correspondiente a 1996, la elección del plan de estudios 1992 se basa en la posibilidad de evaluar la evolución de distintas cohortes que disponen de egresados, situación que no existe respecto del Plan de Estudios 1996.

Hipótesis del experimento: El descubrimiento de relaciones de interés y la generación de una estrategia de visualización a emplear en la gerencia académica, a partir de la evaluación multivariable disponible en la base de datos de alumnos.

Con el fin de poder analizar desde el punto de vista curricular el comportamiento académico, se decidió agrupar las materias del plan de estudios por áreas temáticas que hacen a la estructura curricular del área básica y específica de la carrera. Con el propósito de lograr una estructura de datos adecuada para el posterior procesamiento, se genera una única tabla cuya estructura de datos contiene:

- Un campo por área que contenga el promedio obtenido en las materias que la componen.
- Un campo por área que contiene la lentificación relativa al período en el que se espera que el alumno haya aprobado la última materia del área.

Para la creación de la tabla se utilizó el lenguaje SQL (*Standard Query Language*) con el cual fueron programadas las consultas.

A partir de la obtención de las variables numéricas, se procedió a su estandarización estadística con el objetivo de que sus magnitudes particulares no generen sesgos en la estructura del mapa auto-organizativo.

Para la programación del algoritmo del mapa auto-organizativo, se utilizó el entorno Matlab 5.3. Se utilizaron las librerías de dominio público generadas por el Centro de Investigación en Redes Neuronales de la Universidad Tecnológica de Helsinki.

El conjunto de entrenamiento del mapa SOM contiene todos los casos (alumnos) que lograron completar el ciclo básico de la carrera, con la información de todas las áreas que se completan al tercer año de carrera (4 áreas, 8 variables: promedio y lentificación relativa de cada una de ellas).

La realización del mapa tiene por finalidad detectar las áreas topográficas en las que se ubican el grupo de alumnos que finalizaron su carrera en el período esperado y dónde se halla el grupo de los que se considera desgrane (aquellos que a cuatro años de haberse terminado el Plan 92 no han terminado su carrera). En esta etapa, se busca relacionar esta ubicación en el mapa con el comportamiento (calificaciones y lentificación relativa) en las áreas básicas de la carrera.

Con el fin de evaluar la calidad de los mapas, se pueden ponderar dos propiedades: la primera es el error de cuantificación medido entre los vectores de los datos y las celdas del mapa que presentan la mejor adaptación a los mismos. Se observa un descenso desde el inicio con 3,98 hasta finalizar el entrenamiento en 0,228. La segunda medida corresponde al error topográfico medido como el porcentaje de los vectores datos para los que las 1^ª y 2^ª celdas con menor distancia euclideana no son unidades topológicamente adyacentes. Este parámetro decreció desde 0,955 a 0,0285. Ambas mediciones muestran un buen agrupamiento espacial de los datos.

A continuación, se muestran los resultados gráficos del experimento. En la Figura 1, como resultado del proceso de aprendizaje, se muestra una grilla cuadrada de 25 celdas por lado, etiquetada con el fin de identificar las regiones a las que pertenecen los distintos caso. Así se observa que en el

cuadrante inferior izquierdo predomina una mayor concentración correspondiente a los casos tipo A, que se caracterizan por egresar el sexto año a partir de su ingreso a la carrera (grupo de egresados del plan 92 en tiempo mínimo). Esta región corresponde en relación con las variables particulares, notas y tiempo de finalización de la misma área evaluada: notas más bajas y tiempos de finalización mayores.

Los casos etiquetados como B corresponden a alumnos ya egresados en un tiempo mayor al óptimo (> de 6 años de haber iniciado la carrera). Mientras que la región de impacto de aquellos casos que han sufrido un desgrane, que aún (a junio del 2000) no aprobaron la totalidad de las materias del ciclo superior, llamados D presentan una dispersión más amplia. La región de mínima lentificación, identifica a los candidatos al culminar su carrera con las mismas características. Esta zona se etiquetaría como de grado de avance excelente (cuadrante izquierdo inferior).

Etiquetas




FIGURA 1

Este tipo de herramienta permite además visualizar el aporte al mapa general de cada variable. En la Figura 2 se observa el comportamiento de dos variables: el Promedio en el Área de Matemática Aplicada y el tiempo de finalización del mismo en relación con el tiempo mínimo esperado. También se utilizan estas figuras para mostrar rectángulos negros cuya superficie es función del histograma de la variable. En el gráfico de la izquierda, de la Figura 2, corresponde al Promedio y se muestra el histograma de los impactos de alumnos avanzados A, mientras que en el mapa de la derecha de la misma figura se observa el histograma que pertenece a los que se consideran desgranados de su correspondiente cohorte (tipo D).

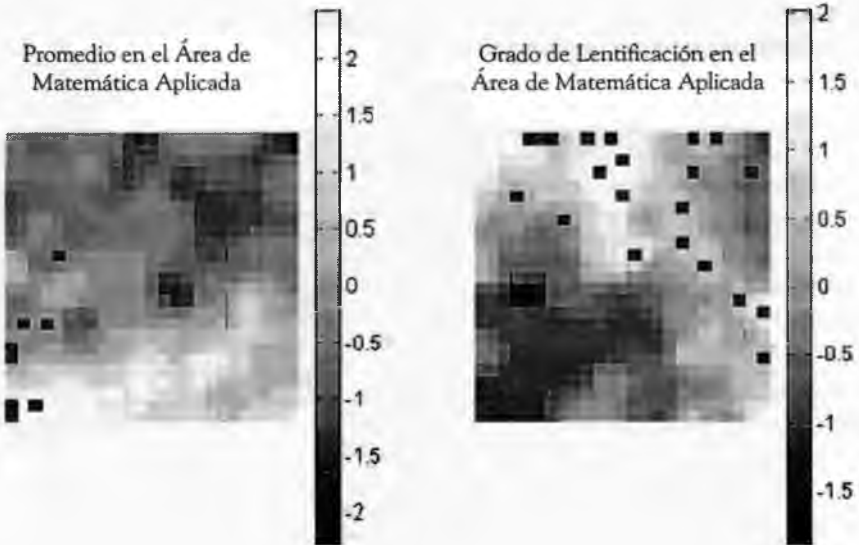


FIGURA 2

En el gráfico de la derecha de la Figura 2 se observa la zona de impacto que pertenece a alumnos cuya tasa de lentificación es mucho mayor y en general los promedios son menores.

La interpretación del mapeo se debe realizar comparando la imagen de los mapas de variables individuales. Así, en la Figura 3, se observan los

Promedios y Tiempos de finalización del Área de Física. Al comparar los tiempos de las áreas Matemática Aplicada y Física se observa que en el de Matemática Aplicada es mayor el área ocupada por los tiempos de lentificación grandes (zonas oscuras que coinciden con los casos de desgrane) comparándola con el área de lentificación del Área Física. A partir de esta interpretación, se logró obtener parte de la explicación correspondiente a la lentificación en la carrera. Se investigó el comportamiento del Área con mayor lentificación (en este caso Matemática Aplicada) y como resultado del análisis se identificó la temática que causa el problema. En consecuencia, se propone estudiar detalladamente los contenidos y metodología de las materias que componen el área problemática.




FIGURA 3

CONCLUSIONES

Como resultado de la experiencia, se ha logrado extraer un conocimiento interesante. A partir de una base de datos del tipo puramente cuantitativa, se han observado situaciones de interés para la toma de decisiones del área académica, como es: el grado de avance relativo junto con la calificación

de una cohorte de alumnos desagregada por áreas del conocimiento.

Es importante considerar la posibilidad de evaluar un mayor número de atributos por alumno (edad, sexo, tipo de colegio del que proviene, condición socioeconómica), situación que posibilitaría el descubrimiento de nuevas relaciones, ciertamente interesante.

El impacto de los resultados es amplio, no desestimando la influencia económica, pues no se debe olvidar la estrecha relación existente en la influencia de la lentificación o grado de repetencia en el cálculo de los costos del egresado.

A partir de la aplicación evaluada se concluye que resulta posible desarrollar aplicaciones de la herramienta en otras áreas de la gestión universitaria.

La Minería de Datos, en la medida que abarca en su proceso un espectro de bases amplio (Bases de Datos Docentes, Planes de Estudio, Recursos Financieros, Presupuesto), es una técnica de soporte a las decisiones de gran utilidad en el gerenciamiento universitario.

BIBLIOGRAFÍA

- Andreu, R. J. y Ricarte y J. (1994), Valor. Estrategia y Sistemas de Información. McGraw-Hill. Madrid 1994.
- Bengio, Y. y Buhmann J. (2000), Embrechts M, Zurada J. *Introduction to the Special Issue on Neural Networks for Data Mining and Knowledge Discovery. IEEE Transaction on Neural Networks*. Vol 11, Nº 3, junio 2000.
- Drucker, Peter (1993), La Sociedad Poscapitalista. Edit. Sudamericana. Buenos Aires. 1993.
- Fanelli, A. (1998) Gestión de las Universidades Públicas. La experiencia internacional. Ministerio de Cultura y Educación, Buenos Aires, Argentina. 1998.
- Fayyad, U. G. y Piatetsky-Shapiro, P. Smyth, R. Uthurusamy (1996) *Advances in Knowledge Discovery and Data Mining*. MIT Press. Cambridge, MA 1996.
- Fayyad, U. G. Piatetsky-Shapiro and P. Smyth. (1996), *Knowledge discovery and data mining: towards a unifying framework*. In Simoudis, E., Han, J., and Fayyad, U., editors, *Proceedings of KDD'96, Second International Conference on Knowledge Discovery & Data Mining*, pages 82-88. AAAI

- Press, Menlo Park, CA. 1996b.
- Haykin S. (1994) *Neural Networks*. Macmillan College Publishing Company 1994.
- Joutsiniemi S., S. Kaski, y T. Larsen (1995), *Self-organizing map in recognition of topographic patterns of EEG spectra*". *IEEE Transactions on Biomedical Engineering*, 42:1062-1068. 1995.
- Kaski S. y T. Kohonen (1996), *Exploratory data analysis by the Self-organizing map: Structures of welfare and poverty in the world*. In Refenes, A.-P. N., Abu-Mostafa, Y., Moody, J., and Weigend, A., editors, *Neural Networks in Financial Engineering. Proceedings of the Third International Conference on Neural Networks in the Capital Markets*, pages 498-507. World Scientific, Singapore. World Scientific 1996.
- Kaski S., T. Honkela, K. Lagus, y T. Kohonen (1996), *Creating an order in digital libraries with self-organizing maps*. In *Proceedings of WCNN'96, World Congress on Neural Networks*, pages 814-817. Lawrence Erlbaum and INNS Press, Mahwah, NJ. Lawrence Erlbaum and INNS Press 1996.
- Kohonen, T. (1990), *The self organizing map*, *IEEE Proceedings*, VOL 78, NO. 9, pp: 1464-1480. 1990.
- Kohonen, T. (1993), *Physiological interpretation of the self-organizing map algorithm*. *IEEE Trans. on Neural Networks* 6, 895-905. 1993.
- Kohonen T. (1982), *Self organized formation of topologically correct feature maps*. *Biological Cybernetics*. Vo. 43. pp 59-69. 1982.
- Mc. Nurlin, B. y R. Sprague (1998), *Information systems management in practice*. 4th Edition. Prentice Hall. N.J. 1998.
- Piatetsky-Shapiro, G., W. Frawley. *Knowledge Discovery in Databases*, AAAI Press / The MIT Press, 1991.
- Passoni, L.I., J. Fritschy, A. Introzzi, F. Clara (1995), *Clustering algorithms as classifiers of blood pressure recordings*". *Computer Simulations in Biomedicine Computational Mechanics Publications*. Boston, 1995.
- Senge, P. (1990), *The Fifth Discipline: the arte and practice of the learning organization*. NY. 1990.
- Vesanto, J. (1999), *SOM- based data visualization*. *Intelligent Data Analysis* 3. pp: 111-126. 1999.