

## PREDICCIÓN DEL RENDIMIENTO ACADÉMICO DE ALUMNOS DE PRIMER AÑO DE UNIVERSIDAD MEDIANTE REDES NEURONALES

EDUARDO A. PORCEL - MARÍA V. LÓPEZ - GLADYS N. DAPOZO  
Facultad de Ciencias Exactas y Naturales y Agrimensura  
Universidad Nacional del Nordeste - ARGENTINA  
eporcel@exa.unne.edu.ar - mvlopez@exa.unne.edu.ar-  
gndapozo@exa.unne.edu.ar

Fecha Recepción: Febrero 2010 - Fecha Aceptación: Diciembre 2010

### RESUMEN

En este trabajo se analiza la relación del rendimiento académico de los alumnos ingresantes a la FACENA - UNNE en Corrientes, Argentina, durante el primer año de carrera, con las características socioeducativas de los mismos. El rendimiento fue medido por la aprobación de los exámenes parciales o finales de la primera materia de Matemática que los alumnos cursan. Se ajustaron modelos de redes neuronales de tipo perceptrón multicapa, obteniéndose un porcentaje de clasificación correcta total de 82,0 %. Entre las variables más relevantes para explicar el rendimiento académico, se encuentran la carrera, el nivel educacional de los padres y el título secundario. La técnica de redes neuronales ha permitido obtener porcentajes elevados de predicción, superiores al obtenido con la regresión logística binaria aplicada al mismo conjunto de datos en estudios anteriores, observándose además que ambas técnicas coinciden en la detección de variables significativas en la estimación del rendimiento académico. A nivel de la gestión de la educación superior, los resultados obtenidos contribuyen a brindar más información para orientar decisiones o acciones concretas destinadas a mejorar los preocupantes índices de abandono y bajo rendimiento de los estudiantes en el primer año de universidad, en particular de la FACENA-UNNE.

**PALABRAS CLAVE:** Rendimiento académico. Ingresantes universitarios. Redes neuronales. Perceptrón multicapa.

### ABSTRACT

In this work, the relation between the academic performance of freshmen from FACENA - UNNE from Corrientes, Argentina and their social-educational characteristics is analyzed. The performance was measured by the number of passed midterm and term Mathematics exams.

Multilayer perceptron neural networks models were adjusted and 82% of correct classification was obtained. The most important variables to explain the academic performance are: the career, the educational level of the parents and the high school certificate obtained. The technique of neural networks has permitted to obtain raised percentages of prediction, higher than the one obtained with the binary logistic regression used in the same data group in previous studies. It was also observed that both techniques agree on the detection of meaningful variables in the estimation of academic performance. At the level of higher education management, the obtained results contribute to bring more information to lead decisions or solid actions oriented to improve the worrying levels of drop out and poor performance of university freshmen, particularly those from FACENA-UNNE.

KEY WORDS: Academic Performance. University freshmen. Neural Networks. Multilayer perceptron.

## 1. INTRODUCCIÓN

Según diversos estudios, el rendimiento académico de los estudiantes se ve influenciado por la interacción de varios factores, que están ligados a características socioeducativas y culturales, los cuales afectan de manera importante el desempeño de los mismos, ya que son determinantes en la preparación del alumno desde antes de su entrada al sistema educativo y durante toda su trayectoria académica.

Por lo tanto, identificar estos factores y analizar conjuntamente su influencia en el rendimiento académico de los alumnos resulta una estrategia interesante de llevar a cabo, para lograr la identificación temprana de elementos de riesgo, y permitir así la implementación oportuna de acciones correctivas en el proceso educativo.

Las redes neuronales artificiales (RNA) cuentan con el potencial para permitir este tipo de análisis, gracias a su excelente comportamiento en problemas de predicción y clasificación. De esta forma, se podrá estimar el rendimiento futuro de los estudiantes teniendo información de diversos factores socioeducativos.

Una red neuronal es un sistema informático reticular (de inspiración neuronal) que aprende de la experiencia mediante la auto-modificación de sus conexiones (Hectht-Nielsen, 1990; Hertz et al, 1991; Wasserman, 1989; Hilera y Martínez, 1995; Martín y Sanz, 1997).

El uso de las RNA implica un leve movimiento desde la lógica de investigación verificativa a la de descubrimiento, debido a que para el uso de esta técnica no es necesario formular previamente una hipótesis, ya que desentrañan la información implícita en los datos. Por este motivo, su uso resulta más eficiente que el análisis dirigido a la verificación, cuando se intenta explorar datos procedentes de repositorios de gran tamaño y complejidad elevada.

Como antecedentes de aplicación de la técnica de redes neuronales en el ámbito de educación pueden mencionarse los trabajos de González (1999), Salgueiro et al (2006), Borracci y Arribalzaga (2005), Zamarripa Topete et al., Santín González (1999), entre otros.

Como herramientas de clasificación, muchos autores están estudiando las relaciones entre las técnicas estadísticas convencionales y los modelos conexionistas (Cherkassky et al, 1994; Flexer, 1995; Michie et al, 1994; Ripley, 1996; Sarle, 1994).

Este trabajo tiene los siguientes objetivos:

- a) Diseñar e implementar un modelo de RNA que permita predecir el rendimiento académico de los alumnos de primer año de la Facultad de Ciencias Exactas y Naturales y Agrimensura de la Universidad Nacional del Nordeste (FACENA-UNNE), en base a los datos socioeducativos disponibles de los mismos.
- b) Contrastar el rendimiento de las RNA con modelos estadísticos convencionales (regresión logística), en un problema de clasificación de una variable cualitativa de dos categorías (el rendimiento académico de los alumnos del primer año de universidad).

## 2. METODOLOGÍA

### 2.1. Redes neuronales artificiales (RNA)

Las redes neuronales son modelos computacionales inspirados en las características neurofisiológicas del cerebro humano y están formadas por un gran número de neuronas dispuestas en varias capas e interconectadas entre sí mediante conexiones con pesos.

"Una neurona, o unidad procesadora, sobre un conjunto de nodos N, es una tripleta (X, f, Y), donde X es un subconjunto de N, Y es un único nodo de N y  $f: \mathbb{R} \rightarrow \mathbb{R}$  es una función neuronal (también llamada función de activación) que calcula un valor de salida para Y basado en una combinación

de los valores de los componentes de X, es decir  $y = f(\sum_{x_i \in X} w_i x_i)$  ..

Los elementos X, Y y f se denominan conjunto de nodos de entrada, nodo de salida, y función neuronal de la unidad neuronal, respectivamente" (Castillo et al., 1999).

"Una red neuronal artificial (RNA) es un par (N,U), donde N es un conjunto de nodos y U es un conjunto de unidades procesadoras sobre N que satisface la siguiente condición: Cada nodo  $x \in N$  tiene que ser un nodo de entrada o de salida de al menos una unidad procesadora de U" (Castillo et al., 1999) (Figura 1).

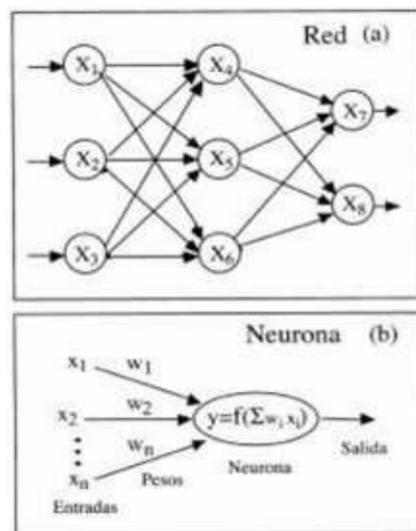


Figura 1: Red neuronal y Neurona

La topología de la red permite clasificar las neuronas de una forma natural como sigue:

Capa de entrada (input layer): Una unidad se dice que está en la capa de entrada de una red neuronal, si es la entrada de al menos una unidad procesadora y no es la salida de ninguna unidad procesadora.

Capa de salida (output layer): Una unidad se dice que está en la capa de salida de una red neuronal, si es la salida de al menos una unidad procesadora y no es la entrada de ninguna unidad procesadora.

Capas intermedias u ocultas (hidden layers): Una unidad se dice que está en la capa intermedia de una red neuronal, si es la entrada de al menos una unidad procesadora y, al mismo tiempo, es la salida de al menos una unidad procesadora (Castillo et al., 1999).

Una de las principales propiedades de las RNA es su capacidad de aprender a partir de unos datos. Las redes neuronales usan un proceso de aprendizaje por analogía donde los pesos de las conexiones son ajustados para reproducir un conjunto de datos representativo del problema a aprender. El procedimiento iterativo de procesamiento de los datos de entrada a través de la red neuronal, propagando hacia atrás los errores a través de la misma para ajustar los pesos, constituye el entrenamiento. Cuando se dispone de valores de entrada y valores de salida observados para los mismos, los pesos se obtienen usualmente minimizando alguna función de error que mide la diferencia entre los valores de salida observados y los calculados por la red neuronal. Esta estrategia de aprendizaje se conoce como Aprendizaje supervisado (Castillo et al., 1999).

Una vez que ha terminado el proceso de aprendizaje y los pesos de la red neuronal han sido calculados, es importante realizar la validación para comprobar la calidad del modelo resultante. Por ejemplo, en el caso de aprendizaje supervisado, una medida de la calidad puede darse en términos de los errores entre los valores de salida deseados y los obtenidos por la red neuronal. También es deseable realizar una validación para obtener una medida de la calidad de predicción del modelo. Con este propósito, los datos disponibles se pueden dividir en dos partes: una destinada al entrenamiento de la red y otra parte a la comprobación o prueba (Castillo et al., 1999).

Las redes neuronales constituyen herramientas analíticas que permiten analizar los datos con el objeto de descubrir y modelar las relaciones funcionales existentes entre las variables. Pueden comportarse como técnicas de aproximación universales. Permiten explorar relaciones o modelos que no podrían ser descubiertos usando procedimientos estadísticos más tradicionales (Rzempoluck, 1997).

El análisis con redes neuronales puede ser muy útil para clasificar una gran cantidad de datos de entrada en categorías de salida. Este método es especialmente apropiado cuando se trabaja con bases de datos incompletas.

Las redes neuronales también se utilizan bastante en problemas de predicción y se han visto integradas en varios sistemas expertos (Lévy Mangin y Varela Mallou, 2003).

## 2.2. Datos

La población analizada fueron los alumnos ingresantes a la FACENA-UNNE en los años 2004 y 2005. Para la descripción de sus características socioeducativas, se utilizó la información que los alumnos registraron en el formulario de ingreso a la universidad. Los datos correspondientes al desempeño académico se obtuvieron del sistema informático de gestión de alumnos de la mencionada unidad académica.

Esta información se incorpora periódicamente en un único almacén de datos con un diseño orientado a las decisiones. Este proceso incluye la integración, depuración y formateo de los datos, siguiendo las técnicas usuales de preprocesado, constituyentes de las etapas previas al modelado y análisis de los datos (Dapozo y Porcel, 2005; Dapozo et al., 2007).

Todas las carreras de la FACENA-UNNE tienen en el primer cuatrimestre del primer año una materia con contenidos matemáticos (principalmente Álgebra). Para aprobar esta materia el alumno dispone de dos modalidades:

- a) Aprobar dos exámenes parciales de contenido práctico y un examen final de contenido teórico.
- b) Aprobar un examen final teórico-práctico.

Para poder avanzar en las materias del segundo cuatrimestre del primer año, el esquema de correlatividades de los planes de estudios requiere, como mínimo, tener aprobados los exámenes parciales de esta asignatura, situación que configura un fuerte condicionamiento de dicho avance.

Por tal motivo, el rendimiento académico se midió mediante una variable dicotómica  $y_i$  que toma el valor 1 (uno) si el alumno aprobó los exámenes parciales o aprobó el examen final de la asignatura (en cualquiera de las modalidades descritas), durante el primer año de estudios, y 0 (cero) en caso contrario.

De este modo, el modelo puede predecir si un alumno regularizará/aprobará o no Álgebra durante el primer año de estudios, a partir de los datos socioeducativos del mismo.

Para el análisis de la relación entre el rendimiento académico y las variables socioeducativas de los alumnos, se consideró el modelo empleado en un estudio previo (Porcel et al., 2009), en el cual se utilizó la técnica de regresión logística binaria en un modelo de efectos principales.

A continuación se enuncian las variables socioeducativas (independientes) que se incluyeron en el modelo, y las categorías que asumen.

AÑO DE INGRESO: 2004, 2005

CARRERA: Agrimensura; Bioquímica; Ingeniería Eléctrica; Ingeniería en Electrónica; Licenciatura en Ciencias Biológicas; Licenciatura en Ciencias Físicas; Licenciatura en Ciencias Químicas; Licenciatura en Matemática; Profesorado en Biología; Profesorado en Ciencias Químicas y del Ambiente; Profesorado en Física y Tecnología; Profesorado en Matemática; Licenciatura en Sistemas de Información.

SEXO: Varón; Mujer.

TIENE MAIL: No; Sí.

TITULO SECUNDARIO: Economía y Gestión de las Organizaciones; Humanidades y Ciencias Sociales; Comunicación, Arte y Diseño; Producción de bienes y servicios; Bachiller común; Peritos Mercantiles; Técnicos; Otros títulos; Ciencias Naturales.

DEPENDENCIA DEL ESTABLECIMIENTO: Nacional, Provincial; Dependiente de la Universidad; Privados religiosos; Privados particulares; Institutos militares.

COBERTURA OBRA SOCIAL: De los padres; Del cónyuge; Propia; Ninguna

ESTUDIO DE LOS PADRES: Se consideró el mayor nivel educativo alcanzado por el padre o la madre. Las categorías son: No hizo estudios/Escuela Primaria Incompleta; Escuela Primaria Completa/ Escuela Secundaria Incompleta; Escuela Secundaria Completa/Estudio Superior No Universitario Incompleto; Estudio Superior No Universitario Completo/Estudio Universitario Incompleto; Estudio Universitario Completo/Estudios de Posgrado.

Las variables relacionadas a la actividad laboral del alumno y de los padres no pudieron ser incluidas en el modelo debido a la notable falta de respuesta registrada en los formularios.

### 2.3. Modelo de RNA para predecir el rendimiento académico

Al conjunto de datos mencionado en la sección 2.2, se aplicaron modelos de tipo perceptrón multicapa (multilayer perceptron -MLP) de tres y cuatro capas, que son alimentadas hacia adelante (feed-forward network). Estos modelos están constituidos por una capa de neuronas de entrada, una o dos capas ocultas, y una capa de salida. Cada neurona se vincula a todas las neuronas de las capas adyacentes, pero no existen conexiones laterales entre las neuronas dentro de cada capa. La capa de entrada contiene tantas neuronas como categorías correspondan a las variables independientes que se desean representar menos uno. La capa de salida corresponde a la variable respuesta, que en este caso es una variable categórica.

Para el entrenamiento de las redes, se presentó un conjunto de datos de entrada, constituido por las variables que definen el perfil socio-educativo enumeradas precedentemente, y su correspondiente valor de salida (rendimiento académico) esperado. Se utilizó un algoritmo de aprendizaje supervisado, ajustándose los pesos de forma que al final de este proceso, una vez aprendida la relación, la red fuese capaz de clasificar correctamente un nuevo patrón que se le presente, indicando si el alumno regularizará/aprobará o no Matemática durante el primer año de estudios.

Para efectuar la validación, se utilizó en cada caso una lista de mediciones independientes de los datos para todas las variables a fin de determinar el grado de predicción de cada modelo. Este conjunto constituyó el 20 % del total de los datos y fue seleccionado al azar.

Debido a que se trata de un problema de clasificación, el objetivo de la red es el de asignar a cada caso, una de una serie de clases (o estimar la probabilidad de pertenencia del caso a cada clase).

La variable categórica de salida fue representada utilizando la técnica "two-state", la cual se encuentra disponible para las variables que pueden tomar dos valores posibles. En este tipo de representación, un valor de 0 se interpreta como un estado, y un valor de 1 como el otro. Las unidades de salida presentan valores de activación continuos con valores entre 0 y 1. Con el fin de asignar definitivamente una clase a partir de la salida calculada, la red debe decidir si la misma se encuentra razonablemente cerca de 0 ó 1. Si no ocurre esto, la clase es considerada como indefinida.

La determinación del nivel de corte o umbral de clasificación es crítica para establecer el poder de predicción de un modelo categórico. En general, se utilizan dos umbrales, uno de aceptación y otro de rechazo.

La salida es considerada como perteneciente a la primera clase si el valor de activación de la neurona de salida está por debajo del umbral de rechazo, y como perteneciente a la segunda clase, si su valor de activación está por encima del umbral de aceptación. Si el valor de activación se encuentra entre los dos umbrales, la clase es considerada como desconocida o indefinida. Si los dos umbrales son iguales, no hay opción de duda. Los umbrales deben ajustarse de acuerdo a las diferentes funciones de activación. Por ejemplo, la función logística proporciona valores entre 0 y 1, la función tangente hiperbólica utiliza el rango de salida (-1,+1), etc.

En este trabajo, se especificó un coeficiente de pérdida que da la relación "costo" de los dos posibles errores de clasificación (de falsos positivos en comparación con falsos negativos). Se asignó un valor igual a 1 al coeficiente de pérdida, indicando que las dos clases son igualmente importantes.

Fueron entrenados cinco modelos de tipo MLP empleando los algoritmos de Retropropagación (BackPropagation - BP) (Patterson, 1996; Fausett, 1994; Haykin, 1994) y de Gradiente descendente (Conjugate Gradient Descent - CG) (Bishop, 1995; Shepherd, 1997), de los cuales fue seleccionado el mejor, considerando como medida de rendimiento de los modelos la proporción de casos clasificados correctamente. La arquitectura de la red fue representada de la forma I:N-N-N:O, donde I es el número de variables de entrada, O es el número de variables de salida, y N es el número de unidades en cada capa (Figura 2).

El algoritmo de Retropropagación fue ejecutado en un período de 100 épocas y el de Gradiente descendente por 20 épocas. Se denomina "época" al procesamiento del conjunto de datos de entrenamiento completo, seguido del conjunto de datos de validación o prueba.

Finalmente, se determinó la importancia de las variables de entrada, mediante un análisis de sensibilidad, el cual cuantifica el porcentaje de contribución de cada variable de entrada a la variable respuesta en el modelo, permitiendo diferenciar las variables socioeducativas que tienen una influencia estadísticamente significativa de aquellas que no difieren significativamente del azar. El análisis se llevó a cabo tratando a cada una de las variables de entrada por vez, como si estuviese "no disponible" (Hunter, 2000). Una vez que se calcularon las sensibilidades para todas las variables, éstas fueron clasificadas en orden.

El análisis de sensibilidad permitió obtener pistas importantes sobre la utilidad de las variables individuales, identificando las variables que podrían ser ignoradas en los análisis posteriores, y aquellas variables clave que siempre deberían mantenerse.

Este análisis valora cada variable de acuerdo con el deterioro en el rendimiento del modelo que se produce si esa variable ya no está disponible para el mismo, asignando un valor de calificación o ranking único a cada variable.

### 3. RESULTADOS Y DISCUSIÓN

En la Tabla 1 se presentan los resultados de la clasificación para el modelo MLP seleccionado, que fue el que ofreció mejores resultados. Puede observarse que para el Rendimiento Malo (0), 1529 casos sobre 1844 han sido clasificados correctamente, mientras que para el Rendimiento Bueno (1) se han clasificado correctamente 322 casos sobre 411, con un porcentaje de clasificación correcta total de 82,0 %.

En la Tabla 2 se visualizan los resultados ofrecidos por el modelo de regresión logística mencionado (Porcel et al, 2009), observándose que para el Rendimiento Malo (0), 1505 casos sobre 1844 han sido clasificados correctamente, mientras que para el Rendimiento Bueno (1) se han clasificado correctamente 181 casos sobre 411, con un porcentaje de clasificación correcta total de 74,8 %, lo cual representa un ajuste menos satisfactorio que el obtenido con el modelo MLP.

Se observa que, si bien ambos modelos clasifican correctamente un elevado porcentaje de casos, el modelo MLP predice adecuadamente tanto el Rendimiento Malo (0) como el Rendimiento Bueno (1), situación que no ocurre con el modelo de regresión logística.

El análisis de sensibilidad del modelo MLP (Tabla 3) permitió identificar a las variables carrera, nivel educacional de los padres y título secundario como de alta sensibilidad, las cuales también resultaron significativas en el modelo de regresión logística. Por otra parte, se observa que en ambos modelos resultaron no significativas o de baja sensibilidad, las variables sexo y dependencia del establecimiento secundario.

La variable tenencia de mail resultó significativa en el modelo de regresión logística, pero de baja sensibilidad en el modelo MLP. Las variables cobertura de obra social y año de ingreso resultaron significativas en el modelo de regresión logística, mientras que en el modelo MLP ocuparon posiciones intermedias en el ranking de sensibilidad.

#### 4. CONCLUSIONES

Se concluye en que el empleo de la técnica de redes neuronales ha permitido obtener porcentajes elevados de predicción, superiores al obtenido con la regresión logística binaria aplicada al mismo conjunto de datos en estudios anteriores. Además, pudo observarse que ambas técnicas coinciden en la detección de variables significativas en la estimación del rendimiento académico.

Por tanto, este modelo orientado a la predicción del rendimiento académico proporciona información sobre la controversia planteada en relación a qué modelos (estadísticos o inteligentes) son más eficientes en la solución de problemas de clasificación, ofreciendo en este caso mejores resultados los modelos inteligentes de redes neuronales.

A futuro se profundizará este estudio con otras técnicas inteligentes, tales como árboles de clasificación, y se realizarán comparaciones entre las mismas.

A nivel de la gestión de la educación superior, los resultados de este trabajo contribuyen a brindar información para orientar decisiones o acciones concretas destinadas a mejorar los preocupantes índices de desgranamiento, abandono y bajo rendimiento de los estudiantes en el primer año de universidad, en particular de la FACENA-UNNE.

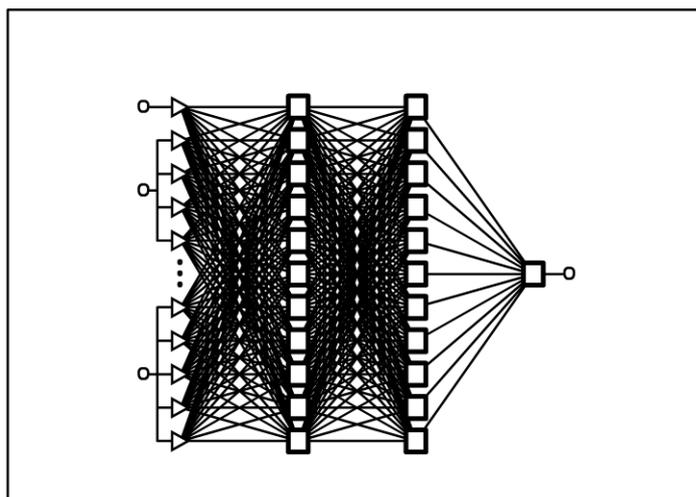


Figura 2: Arquitectura del modelo de tipo MLP seleccionado  
(8:40-11-11-1)

Rendimiento académico	Malo (0)	Bueno (1)	Total	% de clasificación correcto
Malo (0)	1529	315	1844	82,9
Bueno (1)	322	89	411	78,3
Total			2255	82,0

Tabla 1: Matriz de clasificación para el modelo MLP seleccionado

Rendimiento académico	Malo (0)	Bueno (1)	Total	% de clasificación correcto
Malo (0)	1505	339	1844	81,6
Bueno (1)	230	181	411	44,0
Total			2255	74,8

Tabla 2: Matriz de clasificación para el modelo de regresión logística

	AÑO DE INGRESO	CARRERA	SEXO	TIENE MAIL	TITULO SECUNDARIO	DEPEND. DEL ESTAB.	COB. OBRA SOCIAL	ESTUD. DE LOS PADRES
Relación	1,36	1,58	1,27	1,14	1,41	1,20	1,38	1,44
Ranking	5	1	6	8	3	7	4	2

Tabla 3: Análisis de sensibilidad del modelo MLP seleccionado

## 5. REFERENCIAS

BISHOP, C. (1995): "NEURAL NETWORKS FOR PATTERN RECOGNITION". Oxford: University Press. En: LÉVY MANGIN, J.; VARELA MALLOU, J. (2003): "ANÁLISIS MULTIVARIABLE PARA LAS CIENCIAS SOCIALES". Pearson Educación S. A.

BORRACCI, R. A. y ARRIBALZAGA, E. B. (2005): "APLICACIÓN DE ANÁLISIS DE CONGLOMERADOS Y REDES NEURONALES ARTIFICIALES PARA LA CLASIFICACIÓN Y SELECCIÓN DE CANDIDATOS A RESIDENCIAS MÉDICAS". Educación Médica Vol 8 Nº 1. ISSN 1575-1813. Barcelona.

CASTILLO, E.; COBO, A.; GUTIÉRREZ, J.M.; PRUNEDA, R.E. (1999). Introducción a las Redes Funcionales con Aplicaciones. Un Nuevo Paradigma Neuronal". EditorialParaninfo S.A. Madrid. España. pp.5-8; 8-16; 21-24, 30-34, 53-100.

CHERKASSKY, V.; FRIEDMAN, J.H. Y WECHSLER, H. (1994): "FROM STATISTICS TO NEURAL NETWORKS". Springer- Verlag. Berlin.

DAPOZO, G., PORCEL, E., LÓPEZ, M. V.; BOGADO, V. (2007): "Técnicas de preprocesamiento para mejorar la calidad de los datos en un estudio de caracterización de ingresantes universitarios". IX Workshop de Investigadores en Ciencias de la Computación (WICC 2007). Trelew. Chubut. Argentina.

DAPOZO, G.; PORCEL, E. (2005): "Metodología de integración de datos para apoyar el seguimiento y análisis del rendimiento académico de los alumnos de la FACENA". Comunicaciones Científicas y Tecnológicas de la Universidad Nacional del Nordeste 2005. Corrientes. Argentina. Disponible en: <http://www.unne.edu.ar/Web/cyt/com2005/8-Exactas/E-032.pdf>.

FAUSETT, L. (1994): "FUNDAMENTALS OF NEURAL NETWORKS". New York: Prentice Hall. En: LÉVY MANGIN, J.; VARELA MALLOU, J. (2003): "ANÁLISIS MULTIVARIABLE PARA LAS CIENCIAS SOCIALES". Pearson Educación S. A.

FLEXER, A. (1995): "CONNECTIONIST AND STATISTICIANS, FRIENDS OR FOES?". The Austrian Research Institute for Artificial Intelligence. Acceso FTP. Servidor: ai.univie.ac.at.

GONZÁLEZ, D.S. (1999): "DETECCIÓN DE ALUMNOS DE RIESGO Y MEDICIÓN DE LA EFICIENCIA DE CENTROS ESCOLARES MEDIANTE REDES NEURONALES". Biblioteca de Económicas y Empresariales. Servicios de Internet. Universidad Complutense de Madrid.

HAYKIN, S. (1994): "NEURAL NETWORKS: A COMPREHENSIVE FOUNDATION". New York: Macmillan Publishing. En: Lévy Mangin, J.; Varela Mallou, J. (2003). Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A.

HECTHT-NIELSEN, R. (1990): "NEUROCOMPUTING". Addison-Wesley. Cal.

HERTZ, J. KROGH, A. y PALMER, R. (1991): "INTRODUCTION TO THE THEORY OF NEURAL COMPUTATION". Addison-Wesley. Cal.

HILERA, J.R. y MARTÍNEZ, V.J. (1995): "REDES NEURONALES ARTIFICIALES: FUNDAMENTOS, MODELOS Y APLICACIONES". Rama. Madrid.

HUNTER, A.; KENNEDY, L.; HENRY, J; FERGUSON, R.I. (2000): "APPLICATION OF NEURAL NETWORKS AND SENSITIVITY ANALYSIS TO IMPROVED PREDICTION OF TRAUMA SURVIVAL". Computer Methods and Algorithms in Biomedicine 62, 11-19.

LÉVY MANGIN, J.; VARELA MALLOU, J. (2003). "ANÁLISIS MULTIVARIABLE PARA LAS CIENCIAS SOCIALES". Pearson Educación S. A. Madrid. España.

MARTÍN, B. y SANZ, A. (1997): "REDES NEURONALES Y SISTEMAS BORROSOS". Ra-ma. Madrid.

MICHIE, D., SPIEGELHARTER, D.J. y TAYLOR, C.C. (1994): "MACHINE LEARNING, NEURAL AND STATISTICAL CLASSIFICATION". Londres: Ellis Horwood.

PATTERSON, D. (1996): "ARTIFICIAL NEURAL NETWORKS". Singapore: Prentice Hall. En: Lévy Mangin, J.; Varela Mallou, J. (2003). Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A.

PORCEL, E. A.; DAPOZO, G. N., LÓPEZ, M. V. (2009): "PREDICCIÓN DEL RENDIMIENTO ACADÉMICO DE ALUMNOS DE PRIMER AÑO DE LA FACENA (UNNE) EN FUNCIÓN DE SU CARACTERIZACIÓN SOCIOEDUCATIVA". Inédito.

RIPLEY, B.D. (1996). "PATTERN RECOGNITION AND NEURAL NETWORKS". Cambridge Univ. Press. Cambridge, G.B.

RZEMPOLUCK, E. J. (1997): "NEURAL NETWORK DATA ANALYSIS USING SIMULNET". Simon Fraser University. Burnaby. B.C. Canadá. ISBN: 0-387-98255-8. pp. 1-3, 13-75.

SALGUEIRO, F.; COSTA, G.; CÁNEPA, S.; LAGE, F.; KRAUS, G.; FIGUEROA, N.; CATALDI, Z. (2006): "REDES NEURONALES PARA PREDECIR LA APTITUD DEL ALUMNO y SUGERIR ACCIONES". Workshop de Investigadores en Ciencias de la Computación 2006.

SANTÍN GONZÁLEZ, D. (1999): "DETECCIÓN DE ALUMNOS DE RIESGO Y MEDICIÓN DE LA EFICIENCIA DE CENTROS ESCOLARES MEDIANTE REDES NEURONALES". Disponible en: <http://eprints.ucm.es/6674/1/9902.pdf>.

SARLE, W.S. (1994): "NEURAL NETWORKS AND STATISTICAL MODELS". Proceedings of the 19th Annual SAS Group conference, Cary, NC. pps. 1538-1550.

SHEPHERD, A. J. (1997): "SECOND-ORDER METHODS FOR NEURAL NETWORKS". New York: Springer. En: Lévy Mangin, J.; Varela Mallou, J. (2003). Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A.

WASSERMAN, P.D. (1989): "NEURAL COMPUTING: THEORY AND PRACTICE". Van Nostrand Reinhold. N.Y.

ZAMARRIPA TOPETE, J.; SÁNCHEZ RODRÍGUEZ, J. (2007): "PERFILES DE CALIDAD EN EVALUACIÓN INSTITUCIONAL Y PROGRAMA ACADÉMICO, APLICANDO REDES NEURONALES". Anales del VII Congreso internacional "Retos y expectativas de la Universidad". Junio de 2007. Universidad Autónoma de Nuevo León. México. Disponible en: [http://www.congresoretosyexpectativas.udg.mx/Congreso%201/Mesa%20E/mesa-e\\_6.pdf](http://www.congresoretosyexpectativas.udg.mx/Congreso%201/Mesa%20E/mesa-e_6.pdf). Fecha de consulta: Febrero de 2010.