

Redes Neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos

Silvia E. Barreto, María V. López, María G. Ramirez Arballo, Eduardo A. Porcel,
Liliana E. Mata.

Facultad de Ciencias Exactas y Naturales y Agrimensura. Universidad Nacional del Nordeste.
Corrientes. Argentina.

silviaelenabarreto@gmail.com, {mvlopez, mgradelc, eporcel,
carrieri}@exa.unne.edu.ar

Resumen. Este trabajo tiene por objetivo desarrollar modelos de redes neuronales artificiales (RNA) para analizar la incidencia de los conocimientos matemáticos previos de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE, en su rendimiento académico en el primer cuatrimestre del primer año. Se analizaron los datos del estado académico de los alumnos y de sus conocimientos matemáticos previos, siendo obtenidos estos últimos a partir de una evaluación diagnóstica, implementada en 2009, al inicio del curso de nivelación ofrecido a los ingresantes. Se diseñaron modelos de RNA de tipo Perceptrón Multicapa (PM) y Función de Base Radial (FBR), considerando como variables independientes el número de ítems correctos en cada contenido del diagnóstico. El rendimiento académico (variable dependiente) se midió en cada modelo con una variable dicotómica que toma el valor 0 ó 1, si el alumno aprobó ó no los exámenes parciales de Álgebra y Geometría Analítica, materia del primer cuatrimestre del primer año. Los modelos PM y FBR permitieron obtener porcentajes de clasificación correcta total de 81,3%, y 78,8 % respectivamente, los cuales se consideran satisfactorios.

Palabras clave: Redes neuronales. Perceptrón multicapa. Función de Base Radial. Rendimiento académico. Ingresantes universitarios. Conocimientos matemáticos previos.

Abstract. This work aims to develop models of artificial neural networks (ANN) to analyze the incidence of mathematical previous knowledge of students entering the career of Biochemistry of FACENA-UNNE, in their academic performance in the first semester of the first year. We analyzed the data of students' academic status and data on mathematical previous knowledge, the latter being obtained from diagnostic evaluation, implemented in 2009, at the beginning of the leveling course offered to freshmen. ANN models of type Multilayer Perceptron (PM) and Radial Basis Function (RBF) were designed, considering as independent variables the number of correct items in each content of the diagnosis. Academic performance (dependent variable) was

2 **Silvia E. Barreto, María V. López, María G. Ramírez Arballo**, Eduardo A. Porcel, Liliana E. Mata.

measured in each model with a dichotomous variable that takes the value 0 or 1, whether or not the student passed the exams in Algebra and Analytical Geometry, one subject-matter of first semester of the first year. The PM and FBR models have allowed to obtain correct overall classification rates of 81.3% and 78.8% respectively, which are considered satisfactory.

Keywords: Neural Networks. Multilayer Perceptron. Radial Basis Function. Academic Performance. University freshmen. Previous mathematical knowledge.

1 Introducción

La preocupación por el desempeño de los alumnos universitarios, que surge de numerosos y desfavorables indicadores de desgranamiento, abandono y bajo rendimiento académico, ha llevado a las universidades de nuestro país a investigar sobre las causas que subyacen en esta problemática.

La Universidad Nacional del Nordeste (UNNE) no es ajena a esta situación. En este sentido, ha realizado varios estudios con el objeto de aportar información que contribuya a configurar un cuadro de situación al interior de la institución [1]. La Facultad de Ciencias Exactas y Naturales y Agrimensura (FACENA) de la UNNE tampoco escapa a la realidad descrita anteriormente, habiéndose realizado en la institución diferentes estudios relacionados con la temática.

El rendimiento académico es un constructo teórico complejo y multidimensional, atravesado y determinado por múltiples factores sociales, económicos, históricos, institucionales e individuales. Por tal motivo, ha sido representado de diferentes maneras en diversos estudios que han abordado el tema [2] [3] [4].

Muchas son las características del alumnado que han sido consideradas a la hora de relacionarlas con el rendimiento académico, entre las que se encuentran los conocimientos matemáticos previos de los alumnos adquiridos en el nivel medio, los cuales afectarían principalmente su desempeño en el primer año de los estudios. Ello se sustenta en la teoría de [5] sobre el aprendizaje significativo, que supone la revisión de las ideas previas y el establecimiento de nuevas conexiones para lograr aprendizaje por comprensión y no sólo aprendizaje memorístico.

Para analizar la relación entre los conocimientos matemáticos previos y el rendimiento académico en el primer cuatrimestre de primer año de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE, en este trabajo se han desarrollado modelos de Redes Neuronales Artificiales (RNA) de tipo Perceptrón Multicapa (PM) y de Función de Base Radial (FBR).

Las RNA cuentan con el potencial para permitir este tipo de análisis, gracias a su excelente comportamiento en problemas de predicción y clasificación.

Como antecedentes de trabajos realizados aplicando las RNA en el ámbito de la educación, se pueden mencionar [6] y [7], entre muchos otros. Asimismo, autores de este trabajo han analizado la relación del rendimiento académico de los alumnos ingresantes a la FACENA-UNNE en 2004 y 2005, durante el primer año de carrera, con las características socioeducativas de los mismos, mediante modelos RNA de tipo PM y FBR [8] [9] [10] [11] [12] [13].

Redes Neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos

3

Además, en trabajos anteriores, autores de este trabajo han analizado la incidencia de los conocimientos matemáticos previos en el rendimiento académico en el primer año en las carreras de Ingeniería Eléctrica e Ingeniería Electrónica [14] y Licenciatura en Sistemas de Información [15] [16] de la FACENA-UNNE.

Este trabajo tiene los siguientes objetivos:

- Identificar los conocimientos matemáticos previos de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE que resultan explicativos de su rendimiento académico en el primer cuatrimestre del primer año de estudios.
- Diseñar e implementar modelos de RNA para predecir el rendimiento académico de estos alumnos en el mencionado período, en base a los conocimientos matemáticos que poseen al ingresar a la carrera.
- Contrastar la eficiencia de las redes neuronales de base radial con las de tipo perceptrón multicapa, en la predicción del éxito/fracaso académico de los estudiantes en función de los conocimientos matemáticos previos.

El trabajo se compone de cuatro secciones. En esta primera sección se mencionaron antecedentes de trabajos realizados aplicando las RNA en el ámbito de la educación, así como de autores que han analizado la importancia de los conocimientos matemáticos previos sobre el rendimiento académico de los estudiantes, y se exponen los objetivos del trabajo. La segunda sección describe el conjunto de datos y sintetiza la metodología empleada (RNA de tipo PM y FBR). La tercera sección resume los resultados obtenidos y se discuten los mismos. Finalmente se enuncian las conclusiones.

2 Metodología

2.1 Datos

La población analizada consiste en 118 alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en el año 2009.

Los datos sobre los conocimientos matemáticos previos fueron obtenidos a partir de una evaluación diagnóstica, implementada en 2009, al inicio del curso de nivelación ofrecido a los ingresantes. El mencionado test diagnóstico contenía procedimientos básicos del quehacer matemático considerados necesarios para las asignaturas de Matemática de Primer año, comprendidos en el Sistema Básico de Habilidades Matemáticas [17]. En la prueba se incluyó un ejercicio por cada contenido seleccionado, sobre la base de la opinión de profesores de asignaturas de Matemática de primer año de la FACENA-UNNE, quienes consideraron que los mismos resultan necesarios para el cursado de las asignaturas de Matemática de primer año.

Los datos del estado académico de los alumnos se obtuvieron del sistema informático de gestión de alumnos del Departamento Estudios de la Facultad. El rendimiento académico se midió en función de la aprobación ó no de los exámenes parciales de la asignatura Álgebra y Geometría Analítica durante el primer

cuatrimestre de primer año, debido a que esto constituye un requisito para poder avanzar al segundo cuatrimestre, según el esquema de correlatividades del plan de estudios de la carrera.

Los datos sobre la situación académica de los alumnos y sus conocimientos matemáticos previos fueron incorporados en una única base de datos con un diseño orientado a las decisiones. Este proceso incluyó la integración, depuración y formateo de los datos, etapa previa al modelado y análisis de los datos.

2.2 Redes neuronales artificiales

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

$$y = f\left(\sum_{x_i \in X} w_i x_i\right) \quad (1)$$

Los elementos X , Y y f se denominan conjunto de nodos de entrada, nodo de salida, y función neuronal de la unidad neuronal, respectivamente [18].

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 $x_i \in N$ tiene que ser un nodo de entrada o de salida de al menos una unidad procesadora de U [18].

2.2.1 Redes neuronales PM.

Las redes PM están formadas por una capa de entrada, un número arbitrario de capas ocultas, y una capa de salida. Cada una de las neuronas ocultas o de salida recibe una entrada de las neuronas de la capa previa (conexiones hacia atrás), pero no existen conexiones laterales entre las neuronas dentro de cada capa [18].

Las conexiones del PM siempre están dirigidas hacia adelante, es decir, las neuronas de una capa se conectan con las neuronas de la siguiente capa, de ahí que reciben también el nombre de redes alimentadas hacia adelante o redes “feedforward” [19].

El método de aprendizaje más utilizado en el PM es el algoritmo de retro-propagación (backpropagation) [20] el cual está basado en minimizar la función que da el error cuadrático total usando el método del descenso de gradiente [21] [18].

2.2.2 Redes neuronales FBR.

Las redes de tipo FBR se caracterizan porque están formadas por una única capa oculta y cada neurona de esta capa posee un carácter local, en el sentido de que cada neurona oculta de la red se activa en una región diferente del espacio de patrones de entrada. Este carácter local viene dado por el uso de las llamadas funciones de Base

Redes Neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos 5

Radial, generalmente la función Gausiana, como funciones de activación. Las neuronas de la capa de salida de las redes de base radial realizan una combinación lineal de las activaciones de las neuronas ocultas [19].

Las redes FBR han sido aplicadas a una gran variedad de problemas, como análisis de series temporales [22] y procesamiento de imágenes [23], entre otros.

Poseen tres capas de conexión hacia adelante: la capa de entrada, la capa oculta o intermedia y la capa de salida. Las neuronas de la capa de entrada simplemente envían la información a la capa intermedia. Las neuronas de la capa oculta se activan en función de la distancia que separa cada patrón de entrada con respecto al centroide que cada neurona oculta almacena, a la que se le aplica una función radial con forma gaussiana. Las neuronas de la capa de salida son lineales, y simplemente calculan la suma ponderada de las salidas que proporciona la capa oculta [19].

El aprendizaje de las redes de FBR es un método híbrido y se realiza en dos fases: una fase no supervisada donde se realiza la determinación de los centros y amplitudes de las neuronas de capa oculta, y otra fase supervisada donde se determinan los pesos y umbrales de la capa de salida.

2.2.3 Validación de los modelos y análisis de sensibilidad.

Una vez que ha finalizado 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. En el caso de aprendizaje supervisado, una medida de la calidad se calcula en términos de los errores entre los valores de salida deseados y los obtenidos por la red neuronal. 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 [18].

Finalmente, se lleva a cabo un análisis de sensibilidad, el cual cuantifica el porcentaje de contribución de cada variable de entrada a la variable respuesta o de salida del modelo, permitiendo diferenciar las variables independientes que tienen una influencia estadísticamente significativa de aquellas que no difieren significativamente del azar.

3 Resultados y discusión

Se desarrollaron dos modelos de RNA de tipo PM y FBR, para analizar el conjunto de datos descrito en la sección 2.1. El rendimiento académico se midió mediante una variable dicotómica que toma el valor 1 (uno) si el alumno aprobó los exámenes parciales de la asignatura Álgebra y Geometría Analítica durante el primer cuatrimestre de primer año, ó 0 (cero) en caso contrario (variable dependiente o de salida).

Por otra parte, para cada uno de los contenidos evaluados en el mencionado test diagnóstico, los cuales constituyen las variables independientes o de entrada de los modelos, se registró el número de ítems bien resueltos (Tabla 1).

De este modo, estos modelos permiten predecir si un alumno regularizará ó no Álgebra y Geometría Analítica durante el primer cuatrimestre del primer año de

estudios, a partir de los datos obtenidos de la evaluación diagnóstica sobre conocimientos matemáticos previos tomada antes del inicio del primer año. Asimismo, posibilitan identificar cuáles de dichos conocimientos resultan explicativos del rendimiento académico de los alumnos en el primer cuatrimestre del primer año de la carrera.

Para el entrenamiento de las redes PM, se emplearon los algoritmos de aprendizaje supervisado de Retropropagación (BackPropagation - BP) y Gradiente descendente (Conjugate Gradient Descent - CG) [21].

Como se mencionó en la sección 2.2.2, el entrenamiento de las redes FBR comprende dos fases: una no supervisada y otra supervisada [24].

En ambos casos (modelos PM y FBR), se efectuaron varias corridas, utilizando los mismos parámetros en cada corrida, y modificándose automáticamente en cada iteración los pesos asociados a cada conexión. Finalmente fue seleccionado el mejor modelo en cada caso, considerando como medida de rendimiento la proporción de casos clasificados correctamente.

Tabla 1. Variables independientes o de entrada de los modelos PM y FBR

Nombre	Descripción	Valores	Tipo de variable
LENG	Lenguajes simbólico y gráfico	(0 a 3)	Escala
IDENTIF_N	Identificación de nros. como elementos de N (Naturales)	(0 a 7)	Escala
IDENTIF_Z	Identificación de nros. como elementos de Z (Enteros)	(0 a 7)	Escala
IDENTIF_Q	Identificación de nros. como elementos de Q	(0 a 7)	Escala
IDENTIF_I	Identificación de nros. como elementos de I (Irracionales)	(0 a 7)	Escala
IDENTIF_R	Identificación de nros. como elementos de R (Reales)	(0 a 7)	Escala
REP_RECTA	Representación de números en la recta real	(0 a 4)	Escala
PROPORC	Problema de proporcionalidad	(0, 1)	Nominal
OPERAT_R	Operatoria en R (Reales)	(0 a 12)	Escala
AREAS	Áreas de figuras planas	(0 a 4)	Escala
ECUAC	Ecuaciones lineal y cuadrática	(0 a 2)	Escala
TRIG	Resolución de un triángulo rectángulo	(0 a 1)	Nominal
FUNC	Análisis del gráfico de una relación funcional entre dos variables	(0 a 5)	Escala
PORCENT	Problemas de porcentajes	(0 a 2)	Escala

Para cada variable independiente de tipo nominal o categórica, se representaron dos unidades en la capa de entrada, una por cada uno de los valores que puede asumir, mientras que cada variable de tipo escala se representó por un solo nodo de dicha capa. Para la variable dependiente, de tipo nominal, también se asignaron dos unidades en la capa de salida, una por cada uno de los valores que puede tomar.

Redes Neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos 7

El número de unidades de las capas ocultas fue seleccionado en forma automática en ambos modelos.

Para el modelo PM, se utilizó la función sigmoideal como función de activación para las capas ocultas, mientras que para el modelo FBR, se ha empleado la función de base radial normalizada que utiliza la función de activación softmax:

$$y(c_k) = \frac{\exp(c_j)}{\sum \exp(c_j)} \quad (2)$$

En la capa de salida en ambos modelos (PM y FBR), se empleó como función de activación la función identidad que tiene la forma $y(c)=c$.

Para el modelo PM se aplicó el entrenamiento por lotes, empleándose para el mismo el 80 % de los datos, mediante el algoritmo de aprendizaje de retro-propagación con una tasa de aprendizaje igual a 0.3, y un factor de momento de 0.9. Una vez finalizado el aprendizaje, se efectuó la validación utilizando el 20 % de los datos que no se emplearon en el entrenamiento.

Para el modelo FBR, se empleó el 80% de los datos para el entrenamiento y el 20% para la validación de la capacidad predictora de la red entrenada.

El conjunto de datos de validación fue seleccionado al azar en ambos modelos.

La variable de salida, de tipo categórica, puede tomar dos valores posibles: un valor 0 se interpreta como un estado, y un valor 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. En este estudio, el punto de corte o umbral fue fijado en un valor igual a 0.5, el cual permite distinguir entre dos categorías. La salida de la red es considerada como perteneciente a la primera categoría (Rendimiento malo) si el valor de activación de la neurona de salida está por debajo del valor umbral, y como perteneciente a la segunda categoría (Rendimiento bueno), si su valor de activación está por encima de dicho valor.

La arquitectura de las redes que presentan los modelos PM y FBR entrenados tienen 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 (Fig. 1 y 2).

En la Tabla 2 se presentan los resultados de la clasificación para el modelo PM, donde puede observarse que, para el rendimiento malo, 61 casos sobre 71 han sido clasificados correctamente, mientras que para el rendimiento bueno se han clasificado correctamente 35 casos sobre 47, con un porcentaje de clasificación correcta total del 81,3%, el cual se considera satisfactorio.

Tabla 2. Matriz de clasificación para el Modelo PM

Clasificación	Rendimiento Académico		Total
	Malo	Bueno	
Malo	61	12	
Bueno	10	35	
Total	71	47	118
% de clasif. Correcto	85,9%	74,5%	81,3%

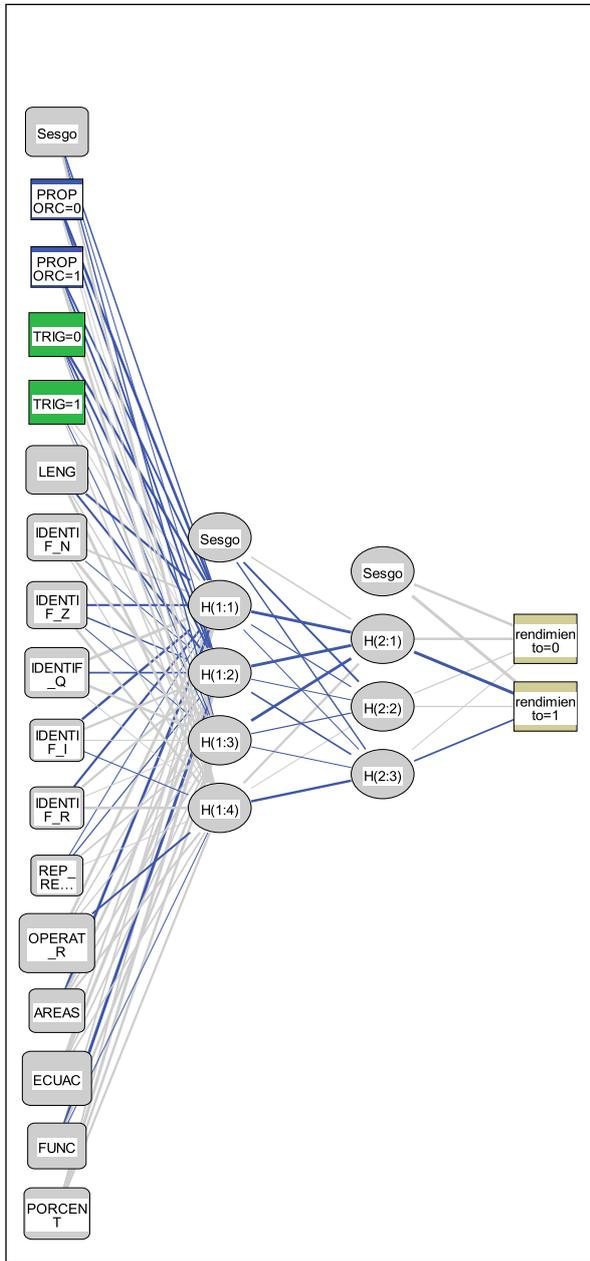


Fig. 1. Arquitectura del modelo PM (16:4:3:2)

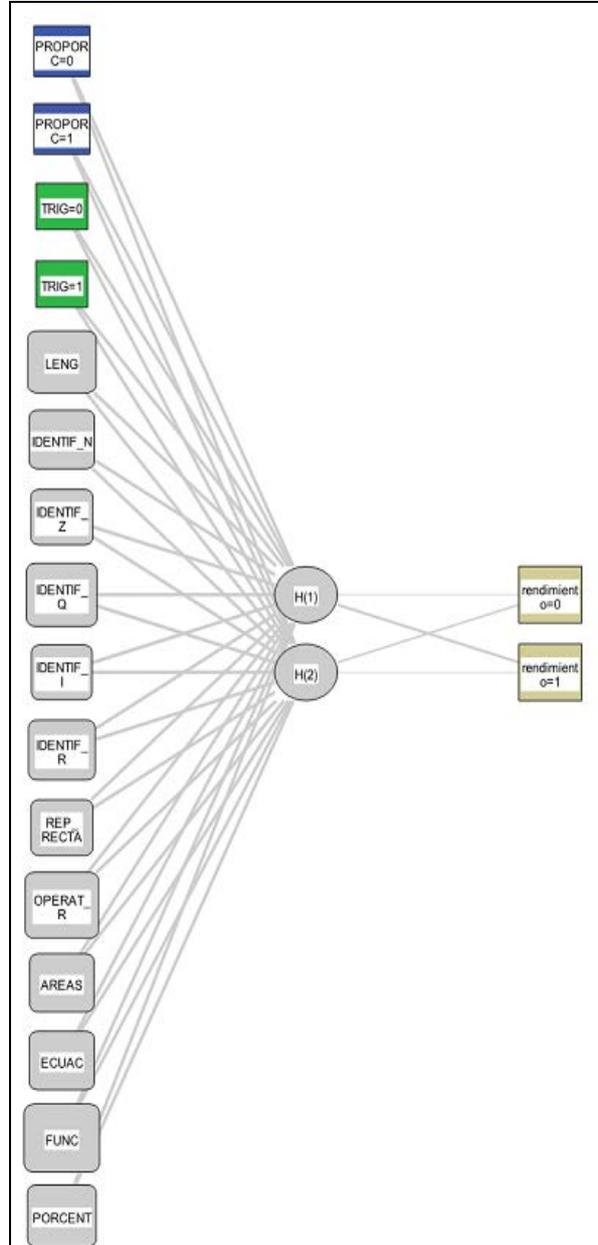


Fig. 2. Arquitectura del modelo FBR (16:2:2)

Redes Neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos 9

En la Tabla 3 se presentan los resultados de la clasificación para el modelo PM, donde puede observarse que, para el rendimiento malo, 62 casos sobre 71 han sido clasificados correctamente, mientras que para el rendimiento bueno se han clasificado correctamente 31 casos sobre 47, con un porcentaje de clasificación correcta total del 78,8%, el cual se considera satisfactorio.

Tabla 3. Matriz de clasificación para el Modelo FBR

Clasificación	Rendimiento Académico		Total
	Malo	Bueno	
Malo	62	16	
Bueno	9	31	
Total	71	47	118
% de clasif. Correcto	87,3%	66%	78,8%

Los porcentajes de clasificación correcta obtenidos en este trabajo resultan superiores a los mencionados por [15], quienes obtuvieron un porcentaje de clasificación correcta total igual a 71,2 %, empleando un modelo de regresión logística. Asimismo, resultan cercanos a los resultados obtenidos por [14] con un modelo de regresión logística para predecir el rendimiento académico de los alumnos de las carreras de Ingeniería de la FACENA-UNNE en función de sus conocimientos matemáticos (79.7 %). Por otra parte, son superiores al obtenido con el modelo de red neuronal PM desarrollado por [16] para predecir el rendimiento académico de los alumnos de Licenciatura en Sistemas de Información de la FACENA-UNNE en función de sus conocimientos matemáticos (73.6 %), e inferiores al porcentaje logrado por [25], quienes obtuvieron un porcentaje de clasificación correcta total igual a 88,1 %, empleando un modelo de red neuronal PM para analizar el rendimiento de los alumnos de ingeniería de la FACENA-UNNE en base a sus conocimientos matemáticos previos.

Se pudo apreciar que el modelo PM clasifica levemente mejor que el modelo FBR, observándose además que ambos modelos presentan porcentajes de clasificación correcta superiores para el rendimiento malo que para el rendimiento bueno.

El análisis de sensibilidad permitió identificar como significativas, en ambos modelos, las variables referidas a los siguientes contenidos: operatoria en Reales (OPERAT_R), Identificación de números como elementos de Q (IDENTIF_Q), Áreas de figuras planas (AREAS) y ecuaciones lineales y cuadráticas (ECUAC) (Tabla 4).

Tabla 4. Análisis de sensibilidad de las variables de entrada del modelo PM y FBR

Variables Independents	Modelo PM Importancia (%)	Modelo FBR Importancia (%)
OPERAT_R	100,0	100,0
IDENTIF_Q	34,0	55,0
AREAS	33,8	52,8
ECUAC	30,1	50,5
IDENTIF_I	28,7	21,3
FUNC	27,8	39,7
IDENTIF_R	24,6	38,1
IDENTIF_Z	23,6	28,8
IDENTIF_N	18,2	21,4
TRIG	14,7	21,4
REP_RECTA	13,5	34,2
PROPORC	12,9	9,4
LENG	11,6	28,1
PORCENT	9,7	26,2

4 Conclusiones

Desde el punto de vista metodológico, la contribución de este trabajo es la utilización de las RNA como técnica de clasificación.

En lo que respecta a su uso para la predicción del rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos, se concluye que los modelos de tipo PM y FBR desarrollados constituyen un instrumento idóneo, como lo demuestran los altos porcentajes de clasificación correcta obtenidos.

Por tanto, debido a la capacidad de generalización de las redes neuronales, estos modelos podrían ser utilizados en períodos futuros, para predecir el rendimiento académico de cada alumno ingresante a la carrera de Bioquímica, en base a los puntajes que obtenga en el test de diagnóstico de conocimientos matemáticos previos.

Además, estos modelos han permitido identificar, entre los conocimientos matemáticos previos con que ingresaron los alumnos a Bioquímica en 2009, los contenidos que resultaron explicativos de su rendimiento académico en la asignatura Álgebra y Geometría Analítica del primer cuatrimestre de primer año. Cabe señalar que los mismos son habilidades fundamentales para desarrollar cualquier contenido matemático, y para el tratamiento de los temas de esta asignatura.

De este modo, este trabajo proporciona información que puede contribuir a orientar estrategias institucionales (cursos de nivelación, tutorías, clases y ejercitación complementarias) para mejorar los faltantes conceptuales y procedimentales de los alumnos ingresantes a las carreras de Bioquímica, en los contenidos matemáticos detectados como decisivos para el buen rendimiento en el primer cuatrimestre del

Redes Neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos 11

primer año, reduciendo de esta manera los preocupantes índices de desgranamiento, abandono y bajo rendimiento de los estudiantes.

5 Referencias

1. Foio, S.: El perfil socioeconómico de los ingresantes en la UNNE y su relación con la deserción en el primer año, la retención y el rendimiento académico. Corrientes, Argentina: Secretaría General de Planeamiento. Universidad Nacional del Nordeste. (2003)
2. Santín González, D.: Detección de Alumnos de Riesgo y Medición de la Eficiencia de Centros Escolares mediante Redes Neuronales.
3. Oloriz M.: Lucchini M., Ferrero E.: Relación entre el rendimiento académico de los ingresantes en carreras de ingeniería y el abandono de los estudios universitarios. VII Coloquio Internacional sobre Gestión Universitaria en América del Sur. Mar del Plata. Argentina. (2007)
4. Cortés Flores A., Palomar Lever, J.: El proceso de admisión como predictor del rendimiento académico en la educación superior. Universitas Psychologica, Vol. 1 Número 001, Pontificia Universidad Javeriana. Bogotá. Colombia. Pp.197-213. (2008)
5. Ausubel, D.P., Novak, J.D., Hanesian, H.: Psicología educativa: un punto de vista cognoscitivo. México, Editorial Trillas. Traducción al español, de Mario Sandoval P., de la segunda edición de Educational psychology: a cognitive view. (1983)
6. González, D.S.: Detección de Alumnos de Riesgo y Medición de la Eficiencia de Centros Escolares mediante Redes Neuronales. Biblioteca de Cs. Económicas y Empresariales. Servicios de Internet. Universidad Complutense de Madrid. (1999)
7. Salgueiro, F., Costa, G., Cánepa, S., Lage, F., Kraus, G., Figueroa, N., Cataldi, Z.: Redes Neuronales para Predecir la Aptitud del Alumno y Sugerir Acciones. VIII Workshop de Investigadores en Ciencias de la Computación (2006)
8. Longoni M. G., López, M. V., Porcel, E. A., Dapozo, G. N.: Desarrollo de modelos de redes neuronales de base radial para la predicción del rendimiento académico de alumnos universitarios. II ERABIO, XXIII ENDIO y XXI EPIO. 15 al 17 de Septiembre de 2010. Tandil. Buenos Aires. Argentina. ISBN: 978-950-9474-49-9. (2010)
9. Longoni M. G., Porcel, E. A., López, M. V., Dapozo, G. N.: Predicción del rendimiento académico de ingresantes universitarios mediante modelos de Redes Neuronales y Regresión logística. X Encuentro Regional de Docentes de Matemática. FACENA-UNNE. Agosto de 2010. Corrientes. Argentina. (2010)
10. Longoni M. G., Porcel, E. A., López, M. V., Dapozo, G. N.: Modelos de Redes Neuronales Perceptrón Multicapa y de Base Radial para la predicción del rendimiento académico de alumnos universitarios. XVI Congreso Argentino de Ciencias de la Computación (CACIC 2010). Octubre de 2010. Morón, Buenos Aires, Argentina, ISBN: 978-950-9474-49- (2010)
11. Porcel E. A., López M. V, Dapozo G.N.: Predicción del rendimiento académico de alumnos de primer año de universidad mediante redes neuronales. Revista de la Escuela de Perfeccionamiento en Investigación Operativa. N° 32. Pgs. 97 a 112. Año 2011. ISSN: 1607-4041. (2011)
12. Longoni M. G., Porcel, E. A., López, M. V.: Modelos de redes neuronales para predecir el rendimiento académico de los alumnos de Bioquímica de la FACENA (UNNE). Reunión de Comunicaciones Científicas y Tecnológicas UNNE 2011. Resistencia, Chaco, Argentina. (2011)

12 **Silvia E. Barreto, María V. López, María G. Ramirez Arballo**, Eduardo A. Porcel, Liliana E. Mata.

13. López M. V., Longoni, M. G., Porcel, E. A.: Modelos Estadísticos y Conexionistas para la predicción del rendimiento académico de alumnos universitarios. Inédito. (2011)
14. Porcel E. A., Ramírez Arballo M. G., Mata L. E., Díaz S. F. Relación de los conocimientos matemáticos de estudiantes de ingeniería (FACENA) al ingresar a la universidad con el rendimiento académico en primer año. Comunicaciones Científicas y Tecnológicas UNNE 2011. Resistencia, Chaco, Argentina. (2011)
15. Porcel E. A., López M. V., Ramírez Arballo, M. G., Mata L. E.: Relación de los conocimientos matemáticos previos con el rendimiento académico en el primer año de una carrera de Sistemas. Inédito. (2011)
16. Barreto S. E., López, M. V., Ramírez Arballo, M. G., Porcel E. A., Mata, L. E.: Modelo de redes neuronales para la predicción del rendimiento académico en primer año de una carrera de sistemas, en función de los conocimientos matemáticos previos. XXV ENDIO y XXIII EPIO. Buenos Aires. Argentina. 30 de mayo al 1 de junio de 2012. (2012)
17. Hernández H., Delgado Rubí J. R., Fernández De Alaíza B.: Cuestiones de didáctica de la matemática. Conceptos y Procedimientos en la educación polimodal y superior. Homo Sapiens. Ediciones Rosario. Argentina. (2001)
18. Castillo, E., Cobo, A., Gutiérrez, J.M., Pruneda, R.E.: Introducción a las Redes Funcionales con Aplicaciones. Un Nuevo Paradigma Neuronal. Editorial Paraninfo S.A. Madrid. España. pp.5-8, 8-16; 21-24, 30-34, 53-100. (1999)
19. Isasi Viñuela P., Galván León I. M.: Redes de Neuronas Artificiales. Un Enfoque Práctico. Pearson Educación S.A., Madrid, España. (2004)
20. Patterson, D.: Artificial Neural Networks. Singapore: Prentice Hall. (1996). En: Lévy Mangin, J., Varela Mallou, J. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
21. Bishop, C.: Neural Networks for Pattern Recognition. Oxford: University Press. (1995). En: Lévy Mangin, J., Varela Mallou, J. Análisis multivariable para las Ciencias Sociales. Pearson Educación S. A. (2003)
22. Moody, J., Darken, C.: Fast Learning In Networks of Locally Tuned Processing Units. Neural Computation, 1 (2), 281–294. (1989)
23. Saha A., Christian J., Tang D., Wu C.: Oriented non-radial basis functions for image coding and analysis. In advanced Neural Information Processing Systems. Morgan Kaufmann. (1991)
24. Vélez-Langs, O., Staffetti, E.: Computación Neuronal y Evolutiva. Redes de Funciones de Base Radial. Asignatura “Computación Neuronal y Evolutiva”. Escuela Superior de Ingeniería Informática. Universidad Rey Juan Carlos. (2007)
25. Barreto S. E., López M. V., Ramírez Arballo M. G., Porcel E. A., Mata L. E.: Redes neuronales para predecir el rendimiento académico de los alumnos de primer año de carreras de Ingeniería en función de sus conocimientos matemáticos previos. Inédito. (2012)