

# Redes neuronales artificiales como sistema de soporte al proceso de toma de decisiones estratégicas: un caso de estudio

*Artificial neural networks as a support system to the strategy decision making process: a case study*

Luciana Tabone, Verónica Mortara

<https://doi.org/10.54139/riiant.v8i31.595>

**Palabras clave:** redes neuronales artificiales, toma de decisiones, pronóstico, gestión estratégica

**Key words:** artificial neural networks, decision making, forecasting, strategic management

## RESUMEN

La aplicación de sistemas de inteligencia artificial en la toma de decisiones estratégicas permite analizar conjuntos de datos de considerable magnitud, y cuando se combina con su destreza para crear modelos predictivos fundamentados, propician toma de decisiones más precisas y exhaustivas. El objetivo de este trabajo es diseñar una red neuronal artificial de predicción de la demanda como apoyo a la gestión estratégica en una organización de salud argentina. Se adopta una metodología de tipo cuantitativa, utilizando el lenguaje de programación R para modelar y analizar las redes neuronales propuestas. Se diseñan doce redes neuronales de tipo perceptrón multicapa con un aprendizaje de retropropagación elástica del error, variando su arquitectura en función del número de capas y neuronas empleadas. Se llevan a cabo los entrenamientos pertinentes y se eligen las cuatro redes con el menor error en la predicción, validadas posteriormente. Finalmente, se selecciona como mejor red a aquella que proporciona el pronóstico más certero en función del grado de correlación. La red seleccionada alcanza una correlación del 90,54%, convirtiéndose en un sólido modelo de predicción de la demanda de tratamientos para la organización.

## ABSTRACT

The application of artificial intelligence systems in strategic decision making allows the analysis of data sets of considerable magnitude, and when combined with their ability to create informed predictive models, they lead to more precise and comprehensive decision making. The objective of this work is the design of an artificial neural network for demand prediction to support the strategic management process in an Argentine health organization. A quantitative methodology is adopted, using the R programming language to model and analyze the proposed neural networks. Twelve multilayer perceptron-type neural networks are designed with elastic error backpropagation learning, varying their architecture depending on the number of layers and neurons used. The relevant training is carried out and the six networks with the lowest prediction error are chosen, which are subsequently subjected to a validation process. Finally, the one that provides the most accurate forecast based on the degree of correlation is selected as the best network. The selected network has reached a correlation of 90.54%, becoming a solid model for predicting the demand for treatments for the organization.

## INTRODUCCIÓN

En la gestión estratégica empresarial resulta ineludible el reconocimiento del proceso de planificación como clave para lograr ventajas competitivas sostenibles en el marco de un entorno globalizado. Para sistematizar y reducir los niveles de riesgo e incertidumbre en el proceso de toma de decisiones estratégicas resulta necesaria la implementación de herramientas que permitan enfrentar problemas y oportunidades. Estas decisiones facilitan una articulación coherente entre los recursos y capacidades organizacionales que garanticen el cumplimiento de los objetivos y la estrategia institucional, permitiendo un desarrollo continuo o ajustes satisfactorios en la planificación estratégica (Zambrano Plúa et al., 2021).

Una de las metas más relevantes de este proceso es predecir los sucesos futuros en base a los hechos ocurridos con anterioridad. En general, la planeación en una organización comienza con el pronóstico de la demanda, que es la información de entrada necesaria para poder conocer sus ventas futuras, los insumos, nivel de capacidad y recursos humanos que se requerirán para satisfacerla y para facilitar el manejo de sus finanzas. De esta manera, se evidencia la importancia de obtener pronósticos certeros y poder planificar, organizar, implementar y controlar logísticamente un conjunto procesos con menor riesgo e incertidumbre y de la forma más efectiva posible (Tabone et al., 2021).

Con el objetivo de que las decisiones tomadas generen el mayor impacto positivo potencial, es que se debe dar prioridad a los procesos críticos y a sus actividades claves para el agregado de valor (Lao León et. al, 2017). El problema de selección del mejor método de pronóstico de la demanda se presenta hoy en día en casi todas las empresas, ya sea de bienes o servicios, y es un aspecto que no se puede evadir en la planificación de la cadena de suministro. Los modelos convencionales utilizados para pronosticar son la regresión, análisis de series de tiempo, promedio móvil, suavizado exponencial, entre otros. En general, este tipo de análisis ha estado dominado por la utilización de métodos estadísticos lineales, sin embargo, cuando los datos presentan relaciones no lineales su aplicación se ha visto limitada (Anderson et al., 2020; Santana, 2006; Zhang et. al, 1998).

Como métodos alternativos a los problemas de predicción, en las últimas décadas se ha aplicado redes neuronales artificiales (RNA). Las RNA son un modelo de un algoritmo computacional inspirado en las redes neuronales biológicas, que tiene la habilidad para aprender y generalizar, permitiendo reconocer patrones, predecir comportamientos y tomar decisiones (Sarmiento-Ramos, 2020; Lazo Chuquiwayta, 2019). Particularmente, las RNA tienen la capacidad de aproximar cualquier función continua o no lineal con una precisión deseada (Menacho Chiok, 2014).

Estudios comparativos de los métodos estadísticos clásicos aplicados al análisis de las series de tiempo con los modelos de RNA han demostrado que estos últimos facilitan la identificación y pronóstico de los patrones de comportamiento en las series, tales como: tendencia, ciclos y estacionalidades, pero también irregularidades como cambios estructurales, datos atípicos, etc. Asimismo, los pronósticos por RNA resultan ser más precisos y con menores medidas de error en la predicción en comparación con los métodos estadísticos clásicos (Menacho Chiok, 2014; Santana, 2006).

La principal fortaleza de las RNA radica en su enfoque libre de suposiciones previas acerca de la relación funcional entre la serie y sus variables explicativas. Gracias a su capacidad de generalización altamente desarrollada, estas redes pueden capturar patrones complejos y extrapolarlos, resultando en pronósticos más precisos. En el contexto de la predicción de series temporales, las RNA se abordan en general como un problema de minimización del error, esto implica ajustar sus parámetros para reducir al mínimo la discrepancia entre los valores reales y las salidas predichas. El creciente interés en la aplicación de redes neuronales en la predicción de series temporales ha

impulsado una intensa actividad investigativa en este campo, evidenciado por el elevado volumen de publicaciones en las que aplican las redes neuronales para el pronóstico de series de tiempo (Fogno Fotso et al., 2020; Soui et al., 2020; Sánchez Sánchez, 2012; Crone y Kourentzes, 2009). El objetivo de este trabajo es el diseño de una RNA capaz de predecir la demanda en una organización de salud mental de la ciudad de Mar del Plata, Argentina. Esta institución brinda un servicio especializado con dos modalidades de tratamiento: hospital de día y de medio día. El proceso de servicio varía según las modalidades y su duración oscila entre 2 a 3 años, conforme a la evolución de cada paciente. Es un tratamiento cubierto por obras sociales, prepagas o servicios de salud que posea cada paciente o en forma particular. Las decisiones estratégicas son tomadas por la Gerencia, que pretende lograr que la organización funcione sistémicamente en pos de sus objetivos estratégicos, en búsqueda de la mejora de la eficiencia y calidad del servicio. Actualmente, utilizan herramientas de pronóstico informales con cálculos manuales en base a datos históricos que presentan relaciones no lineales. Con la aplicación de RNA se pretende contribuir a la obtención de pronósticos más certeros, mejorando el nivel de servicio y su gestión estratégica.

## METODOLOGÍA

Para la predicción de la demanda de la organización en estudio se adopta una metodología de tipo cuantitativa de

carácter empírico ya que se analiza un fenómeno contemporáneo dentro de su entorno. Los pasos a seguir para su desarrollo son:

1.- *Recopilación, procesamiento y normalización de datos históricos de la demanda de las distintas modalidades de tratamiento.*

2.- *Diseño de la RNA base.*

3.- *Entrenamiento de las diferentes arquitecturas de la RNA propuestas.*

4.- *Determinación de las RNA con menor error de predicción.*

5.- *Validación de las RNA seleccionadas en el paso anterior.*

6.- *Selección de la mejor RNA en base a su capacidad de predicción.*

Para el diseño y análisis de la RNA se emplea el lenguaje de programación R mediante la aplicación RStudio. Los paquetes utilizados son neuralnet, nnet, NeuralNetTools, plyr, readxl, psych y kableExtra (Anaconda, 2021; Velásquez et al., 2011).

La información necesaria se obtiene a partir de una base de datos suministrados por la organización que contiene la demanda de las distintas modalidades de tratamientos ofrecidas desde el año 2015 hasta mediados de 2022. Para su posterior procesamiento, se realiza una normalización de los datos obtenidos. De la muestra total de 120 observaciones se generan las muestras de entrenamiento y validación de 104 y 16 observaciones respectivamente.

Se construye una RNA base con una arquitectura multicapa, particularmente el Perceptrón Multicapas, compuesta por una capa de entrada, al menos una capa intermedia y una capa de salida. Este tipo de red ha demostrado ser un aproximador universal de funciones con una baja dificultad de uso y aplicación. Posee una elevada capacidad de generalización y

robustez y se ha convertido en el tipo de RNA de mayor aplicación para el cálculo de pronósticos (Lao León et al., 2017).

El algoritmo de aprendizaje más utilizado en este tipo de redes es el de retropropagación del error, tratando de minimizar la función del error entre la entrada y salida deseada y la del modelo neuronal a partir de un conjunto de observaciones ya clasificadas (Zambrano Matamala et al., 2011). Sin embargo, presenta ciertas desventajas, como son la lentitud de convergencia, el sobre aprendizaje y no garantiza el mínimo global de la función de error, tan solo un mínimo local (Riedmiller, 1994; Marcano Cedeño, 2010; Polo et. al, 2015).

En el presente trabajo se selecciona una variante que evita estos inconvenientes que es el algoritmo de retropropagación elástica, basado en un gradiente más adecuado para entrenar la RNA y considerado como uno de los más robustos para la estimación de sus parámetros. Este algoritmo trata de encontrar los valores de los parámetros tal que se minimicen las diferencias entre los valores deseados y los valores calculados por la red (Polo et al., 2015).

Las variables de entrada seleccionadas para el modelo propuesto son aquellas que influyen en el comportamiento de la demanda de este servicio. Estas variables son modalidad de tratamiento, mes de ingreso y tipo de cobertura. En la Tabla 1 se muestran sus categorías y codificación. La variable de salida de la red es la cantidad demandada de tratamientos.

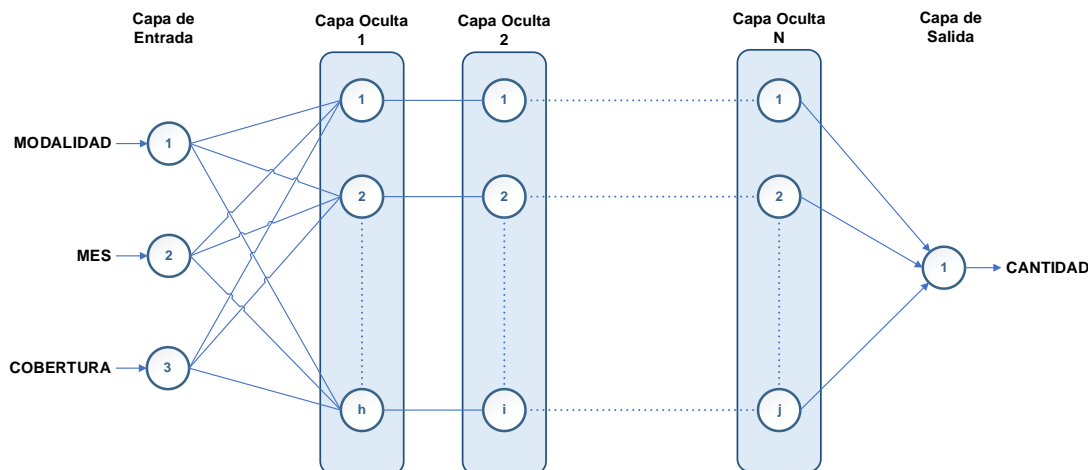
Tabla 1. Variables de entrada de la RNA

VARIABLES DE ENTRADA	CATEGORÍAS	CODIFICACIÓN
Modalidad de tratamiento	Hospital de medio día	0
	Hospital de día	1
Mes de ingreso	Enero a Diciembre	1 a 12
Tipo de Cobertura	Con cobertura	0
	Sin cobertura	1

En la Figura 1 se presenta la arquitectura de la RNA base. Como puede observarse, la capa de entrada posee 3 neuronas que corresponden a cada variable de entrada,

mientras que la capa de salida tiene una única neurona que representa a la variable de salida.

Figura 1. Arquitectura base de la RNA



Mediante el método de prueba y error se hallan los valores más adecuados del número de capas ocultas y número de neuronas por cada capa, planteando un conjunto de variaciones posibles de la arquitectura base de la RNA. Se realizan los entrenamientos correspondientes y se seleccionan aquellas que reporten el menor error de predicción, utilizando con indicador el error cuadrático medio (ECM) como se muestra en la Ecuación 1.

$$ECM = \frac{1}{N} SSE \tag{1}$$

Donde:

*N*: número de muestras.

*SSE*: suma de los cuadrados del error.

Finalmente, se validan las RNA seleccionadas y se elige la que proporciona el pronóstico más certero en función del grado de correlación.

## RESULTADOS y DISCUSIÓN

El primer paso de la metodología propuesta consiste en el procesamiento de la información suministrada por la organización respecto a la demanda de tratamientos desde el año 2015 hasta el mes de junio de 2022. Se obtienen los datos relativos a las variables consideradas para las etapas de entrenamiento y validación de las RNA y luego se procede a su normalización.

Seguidamente, se desarrolla en el entorno R la configuración de doce variaciones posibles de la RNA base mediante el método de prueba y error. A modo de ejemplo, se muestra el comando del pronosticador de la RNA1 y el detalle de su arquitectura:

- Comando:

```
RNA_1<-          neuralnet(CANTIDAD~
MODALIDAD + MES + COBERTURA , data
= RNA_train, hidden = (4), threshold = 0.01,
```

```
stepmax = 1e+05, rep = 100, startweights =
NULL,          learningrate.limit = NULL,
learningrate.factor = list(minus = 0.5, plus =
1.2), learningrate = NULL, lifesign = "none",
lifesign.step = 1000, algorithm = "rprop+",
err.fct = "sse", act.fct = "logistic", linear.output
= TRUE, exclude = NULL, constant.weights =
NULL, likelihood = FALSE)
```

- Función de aprendizaje: rprop+ (retropropagación elástica del error)
- Número de réplicas: 100
- Función de Activación: logistic (logística)
- Factor de error: sse (suma de los errores al cuadrado)
- Número de capas: 3 (1 de entrada, 1 ocultas y 1 de salida)
- Número de neuronas por capa: 3 neuronas en la capa de entrada, 4 neuronas en la capa oculta y 1 neurona en la capa de salida.

En la Tabla 2 se presentan los resultados obtenidos a partir del entrenamiento de las configuraciones propuestas de redes.

**Tabla 2.** Resultados de la etapa de entrenamiento

RNA	Capas ocultas				Pasos	SSE	ECM
	1	2	3	4			
1	4	0	0	0	545	0,836187	0,008040
2	1	4	0	0	62	0,862402	0,008292
3	1	8	0	0	403	0,855638	0,008227
4	1	4	4	0	1000	0,850663	0,008179
5	4	4	4	0	79	0,847271	0,008147
6	4	4	8	0	147	0,841996	0,008096
7	1	8	1	0	356	0,856892	0,008239
8	1	8	4	0	505	0,849835	0,008171
9	1	4	4	1	546	0,861351	0,008282
10	1	4	4	4	218	0,86579	0,008325
11	1	4	4	8	312	0,859823	0,008268
12	4	4	8	1	204	0,838236	0,008060

Del análisis de los resultados obtenidos se seleccionan cuatro configuraciones correspondientes al menor error de predicción (menor ECM), que son: RNA1, RNA5, RNA6 y RNA12.

Se realiza el proceso de validación para las redes seleccionadas y se determina para cada una su capacidad de predicción. Se considera como la mejor red a aquella que presente el mayor grado de correlación según se muestra en la Tabla 3.

Tabla 3. Resultados de la etapa de validación

RNA	Capas ocultas				Pasos	SSE	ECM	Coeficiente de Correlación
	1	2	3	4				
1	4	0	0	0	545	0,836187	0,008040	<b>0,9053792</b>
5	4	4	4	0	79	0,847271	0,008147	0,8991035
6	4	4	8	0	147	0,841996	0,008096	0,9027653
12	4	4	8	1	204	0,838236	0,008060	0,9021329

De esta manera, la mejor red es la RNA1 compuesta por 3 capas: 1 capa de entrada, 1 capa oculta y una capa de salida. La capa de entrada posee 3 neuronas, la capa ocultas 4 neuronas y la capa de salida 1 neurona. El EMC obtenido en la etapa de entrenamiento es de 0,008040 mientras que en la etapa de validación ha logrado predecir la demanda con un grado de correlación del 90,53792%.

Se puede observar que existe poca variación en los valores obtenidos de ECM para las redes consideradas en la etapa de entrenamiento, sin embargo, al momento de la validación, solamente se consideraron aquellas que alcanzaron los menores valores de este indicador.

Respecto a la selección final, la mejor red resulta ser la del menor ECM y logra obtener un resultado superior en su capacidad de predicción. Como se explica en los apartados anteriores, la capacidad de predicción es medida en términos del coeficiente de correlación entre los valores pronosticados por la red y la muestra de validación. Un coeficiente del orden del 90% indica una relación positiva fuerte entre las variables de estudio, alcanzando un coeficiente de regresión de 0,8197 lo que significa que el 82% de la variación es explicada mediante este modelo. De esta manera se puede inferir que la red RNA1 seleccionada es un buen modelo de predicción de la demanda de tratamientos para la organización.

### CONCLUSIONES

El presente trabajo ha logrado diseñar una RNA para predecir la demanda de tratamientos de una organización de salud marplatense, cuya pertinencia fue

demostrada a través de una aplicación concreta.

Se analizaron doce alternativas de RNA diseñadas con una arquitectura de tipo Perceptrón Multicapa y un aprendizaje del tipo retro propagación elástica del error,

considerando las principales variables que influyen en la demanda de la organización. Las redes con menor ECM fueron aquellas con una arquitectura de 4 neuronas en la primera capa oculta, sin embargo, la adición de un mayor número de capas ocultas no mejoró su capacidad de predicción. Luego de un proceso de validación, se selecciona la mejor en función de su capacidad de predicción.

La RNA seleccionada ha permitido pronosticar la demanda con un grado de correlación mayor al 90%, alcanzando un desempeño apropiado para su utilización en el proceso de toma de decisiones estratégica de la organización bajo estudio. La utilización del lenguaje de programación R ha facilitado el tratamiento de los datos y posterior procesamiento.

Se concluye que la toma de decisiones basada en datos certeros sobre el comportamiento de la demanda representa una mejora significativa en los procesos de gestión de la organización. Esta metodología de pronóstico no solo aborda la problemática actual, sino que también proporciona las bases para una toma de decisiones más informada, efectiva y sistémica. La capacidad predictiva demostrada por la RNA facilitará la identificación de patrones complejos y no lineales en los datos históricos, ofreciendo información más precisa y detallada del

comportamiento de la demanda. Este enfoque no solo mejora la capacidad de respuesta a las necesidades de los clientes, sino que también optimiza la asignación de recursos, contribuyendo a una gestión estratégica efectiva de los procesos clave en la cadena de valor.

Se estima que la implementación de esta nueva metodología no solo resolverá los desafíos existentes en el proceso de pronóstico, sino que también posicionará a la organización en una ventaja estratégica, permitiéndole adaptarse de manera más eficiente a las dinámicas cambiantes del entorno. La adopción de la RNA no solo representa una solución a problemas específicos, sino que también propiciará un proceso de mejora continua y una búsqueda constante de la excelencia operativa en el contexto de la gestión estratégica de la organización, lo que se traduce en un aporte de valor sustancial para la organización y sus clientes.

Como trabajo futuro se propone continuar la investigación mediante estudios comparativos de estas metodologías frente a los métodos convencionales para pronosticar series de tiempo. Asimismo, se recomienda ensayar con otras topologías de redes neuronales y algoritmos de predicción.

## REFERENCIAS

Anaconda, Inc. (2023). Anaconda Documentation: R language packages for Anaconda.

<https://docs.anaconda.com/anaconda/package/s/r-language-pkg-docs/>



- Anderson, D., Sweeney, D., Williams, T.; Camm, J., & Cochran, J. (2020). *Estadística para negocios y economía, 17a edición*. Cengage.
- Crone, S., & Kourentzes, N. (2009). Input-variable specification for Neural Networks - An analysis of forecasting low and high time series frequency. *Proceedings of the International Joint Conference on Neural Networks*. Atlanta, USA. <https://doi.org/10.1109/IJCNN.2009.5179046>
- Fogno Fotso, H. R., Kaze, C. & Kenmoé, G. (2020). Optimal Input Variables Disposition of Artificial Neural Networks Models for Enhancing Time Series Forecasting Accuracy. *Applied Artificial Intelligence*, 34(11), 792-815. <https://doi.org/10.1080/08839514.2020.1782003>
- Hornik, K., Stinchcombe, M., & White, H. (1989) Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Lao León, Y., Rivas Méndez, A., Pérez Pravia, M., & Marrero Delgado, F. (2017) Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales. *Ciencias Holguín*, 23(1), 43-59. <http://www.ciencias.holguin.cu/index.php/cienciasholguin/article/view/995/0>
- Lazo Chuquiwayta, H. (2019). *Modelo de redes neuronales artificiales para el pronóstico del número de visitantes extranjeros a Machu Picchu en comparación con la metodología de Box y Jenkins* [Tesis de Maestría, Universidad Nacional de San Antonio Abad del Cusco]. Repositorio UNSAAC. <https://repositorio.unsaac.edu.pe/bitstream/handle/20.500.12918/4637>
- Marcano Cedeño, Alexis Enrique (2010). *Un modelo neuronal basado en la metaplasticidad para la clasificación de objetos en señales 1-d y 2-d* [Tesis de Doctorado, Universidad Politécnica de Madrid]. Archivo UPM. <https://doi.org/10.20868/UPM.thesis.5125>
- Menacho Chiok, C. (2014). Modelos de regresión lineal con redes neuronales. *Anales Científicos*, 75(2), 253-260. <https://doi.org/10.21704/ac.v75i2.961>
- Polo, D., Caballero, L., & Gómez, E. (2015) Comparación de redes neuronales aplicadas a la predicción de series de tiempo. *Prospectiva*, 13(2), 88-95. <https://doi.org/10.15665/rp.v13i2.491>
- Riedmiller, M. (1994) Advanced supervised learning in multi-layer perceptrons - from backpropagation to adaptive learning algorithms. *Computer Standards & Interfaces*, 16(3), 265-278. [https://doi.org/10.1016/0920-5489\(94\)90017-5](https://doi.org/10.1016/0920-5489(94)90017-5)
- Sánchez Sánchez, P. A. (2012). *Una nueva metodología de entrenamiento de redes neuronales y sus implicaciones en la selección de modelos* [Tesis de Doctorado, Universidad Nacional de Colombia]. Repositorio UNAL. <https://repositorio.unal.edu.co/handle/unal/9818>
- Santana, J. C. (2006). Predicción de series temporales con redes neuronales: una aplicación a la inflación colombiana. *Revista Colombiana de Estadística*, 29(1), 77-92. <https://repositorio.unal.edu.co/handle/unal/40269>
- Sarmiento-Ramos, J. L. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ing.*, 19(4), 1-18. <https://doi.org/10.18273/revuin.v19n4-2020001>
- Soui, M., Smiti, S., Mkaouer, M.W., & Ejbali, R. (2020). Bankruptcy Prediction Using Stacked Auto-Encoders. *Applied Artificial Intelligence*, 34(1), 80-100. <https://doi.org/10.1080/08839514.2019.1691849>
- Tabone, L., Mortara, V., Zanfrillo, A. & Morcela, A. (2021). Diseño de redes neuronales artificiales para la predicción de la demanda de productos farmacéuticos. *Proceedings XV*

- EnIDI. Mendoza, Argentina. [https://enidi.org.ar/?page\\_id=17](https://enidi.org.ar/?page_id=17)
- Velásquez, J.; Zambrano, C. & Vélez, L. (2011). ARNN: un paquete para la predicción de series de tiempo usando redes neuronales autorregresivas. *Revista Avances en Sistemas e Informática*, 8(2), 177-181. <https://revistas.unal.edu.co/index.php/avances/article/view/26744>
- Zambrano Plúa, I. E., Quindemil Torrijo, E. M., & Rumbaut León, F. (2021). Gestión documental en universidades: Una mirada desde Latinoamérica. *Revista de Ciencias Humanísticas y Sociales*, 6, 108-119.
- <https://doi.org/10.33936/rehuso.v6iEspecial.3779>
- Zambrano Matamala, C., Rojas Díaz, D., Carvajal Cuello, K., & Acuña Leiva, G. (2011). Análisis de rendimiento académico estudiantil usando data warehouse y redes neuronales. *Ingeniare. Revista Chilena de Ingeniería*, 19(3), 369–381. <http://dx.doi.org/10.4067/S0718-33052011000300007>
- Zhang, P., Patuwo, E., & Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35–62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)

#### Autoras

**Luciana Belén Tabone.** Ingeniera Industrial y Especialista en Gestión de la Tecnología y la Innovación, Universidad Nacional de Mar del Plata, Argentina. Docente e investigadora del Dto. de Ingeniería Industrial, Facultad de Ingeniería, Universidad Nacional de Mar del Plata, Argentina.

**ORCID:** <https://orcid.org/0000-0003-3755-5336>

**Email:** [ltabone@fi.mdp.edu.ar](mailto:ltabone@fi.mdp.edu.ar)

**Verónica Aída Mortara.** Ingeniera Electricista y Especialista en Administración de Negocios, Universidad Nacional de Mar del Plata, Argentina. Docente e investigadora del Dto. de Ingeniería Industrial, Facultad de Ingeniería, Universidad Nacional de Mar del Plata, Argentina.

**ORCID:** <https://orcid.org/0000-0003-2387-2963>

**Email:** [vmortara@fi.mdp.edu.ar](mailto:vmortara@fi.mdp.edu.ar)

**Recibido:** 17-08-2023

**Aceptado:** 06-12-2023