

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), enero-febrero 2025,
Volumen 9, Número 1.

https://doi.org/10.37811/cl_rcm.v9i1

**EL RENDIMIENTO ACADÉMICO DE LOS ESTUDIANTES
DE LA UNIVERSIDAD NACIONAL DEL SANTA SEGÚN
LOS FACTORES SOCIOECONÓMICOS DETERMINADOS
MEDIANTE UNA RED NEURONAL SUPERVISADA**

ACADEMIC PERFORMANCE OF STUDENTS OF THE NATIONAL
UNIVERSITY OF SANTA CRUZ ACCORDING TO SOCIOECONOMIC
FACTORS DETERMINED BY A SUPERVISED NEURAL NETWORK

Luzbeth Karin Navarrete Leal

Universidad Nacional del Santa, Perú

Herón Juan Morales Marchena

Universidad Nacional del Santa, Perú

Manuel Abelardo Alcántara Ramírez

Universidad Nacional del Santa, Perú

DOI: https://doi.org/10.37811/cl_rcm.v9i1.16415

El Rendimiento Académico de los Estudiantes de la Universidad Nacional del Santa según los Factores Socioeconómicos Determinados Mediante una Red Neuronal Supervisada

Luzbeth Karin Navarrete Leal¹

lux.krn.n.leal@gmail.com

<https://orcid.org/0009-0007-3403-5358>

Universidad Nacional del Santa
Chimbote
Perú

Herón Juan Morales Marchena

hmorales@uns.edu.pe

<https://orcid.org/0000-0002-5394-0958>

Universidad Nacional del Santa
Chimbote
Perú

Manuel Abelardo Alcántara Ramírez

malcantara@untels.edu.pe

<https://orcid.org/0000-0001-9490-8447>

Universidad Nacional Tecnológica de Lima Sur
Lima
Perú

RESUMEN

La investigación tuvo como objetivo desarrollar una red neuronal supervisada para predecir el rendimiento académico de los estudiantes de la Universidad Nacional del Santa, considerando factores socioeconómicos. Utilizando un enfoque cuantitativo y un diseño no experimental, se analizó la relación entre las variables socioeconómicas y los resultados académicos. Se empleó una red neuronal BackPropagation implementada en la herramienta nntool de MATLAB, con funciones de activación Tansig y el algoritmo de optimización Levenberg-Marquardt. El modelo de la red fue entrenado con el 60% de los datos históricos obtenidos de fichas socioeconómicas, mientras que el 40% restante se utilizó para la evaluación. Los resultados mostraron que el modelo era eficaz, aunque se observó que los errores no eran significativos y podrían reducirse mediante la adición de más capas y neuronas en la red. La investigación concluye que la red neuronal desarrollada es una herramienta útil para predecir el rendimiento académico en función de factores socioeconómicos, destacando la importancia de estos factores en el rendimiento de los estudiantes.

Palabras clave: rendimiento académico, factores socioeconómicos, ficha socioeconómica, red neuronal artificial, función de activación

¹ Autor principal.

Correspondencia: lux.krn.n.leal@gmail.com

Academic Performance of Students of the National University of Santa Cruz according to Socioeconomic Factors Determined by a Supervised Neural Network

ABSTRACT

The research aimed to develop a supervised neural network to predict the academic performance of students at the Universidad Nacional del Santa, considering socioeconomic factors. Using a quantitative approach and a non-experimental design, the relationship between socioeconomic variables and academic results was analyzed. A BackPropagation neural network implemented in the MATLAB nntool tool was used, with Tansig activation functions and the Levenberg-Marquardt optimization algorithm. The network model was trained with 60% of the historical data obtained from socioeconomic records, while the remaining 40% was used for evaluation. The results showed that the model was effective, although it was observed that the errors were not significant and could be reduced by adding more layers and neurons in the network. The research concludes that the developed neural network is a useful tool to predict academic performance based on socioeconomic factors, highlighting the importance of these factors in student performance.

Keywords: academic performance, socioeconomic factors, socioeconomic record, artificial neural network, activation function

Artículo recibido 10 diciembre 2024
Aceptado para publicación: 30 enero 2025



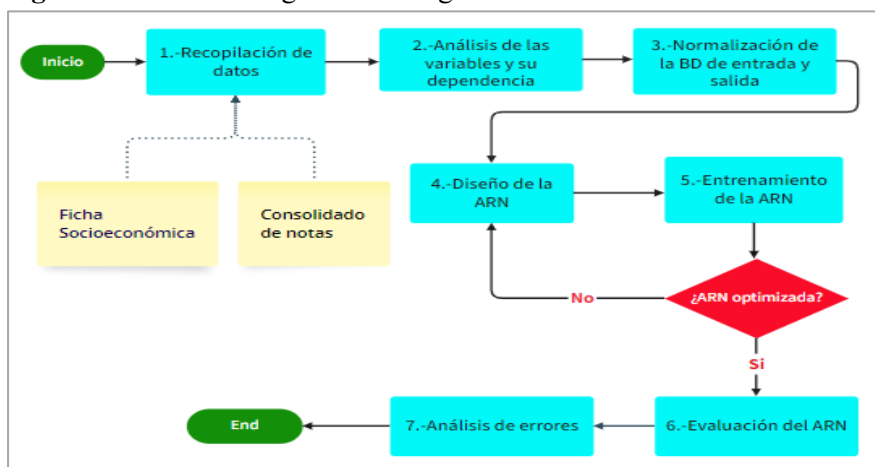
INTRODUCCIÓN

El rendimiento académico de los estudiantes ha sido objeto de estudio durante décadas, dada su relevancia en el desarrollo personal y profesional de los individuos y en el progreso social y económico de las comunidades. Entre los diversos factores que influyen en el rendimiento académico, los socioeconómicos juegan un papel fundamental. Variables como el nivel educativo de los padres, el acceso a recursos educativos y las condiciones del entorno familiar afectan directamente el desempeño de los estudiantes. En este contexto, la presente investigación se enfoca en cómo estos factores socioeconómicos pueden predecir el rendimiento académico, utilizando redes neuronales supervisadas, un enfoque avanzado en análisis de datos. Las redes neuronales, inspiradas en el cerebro humano, son capaces de identificar patrones complejos en grandes volúmenes de información, superando las limitaciones de los métodos estadísticos tradicionales. Esta investigación busca integrar la neurociencia artificial con la sociología educativa, para mejorar la comprensión y el apoyo a los estudiantes en función de su contexto socioeconómico.

METODOLOGÍA

La presente investigación presenta un enfoque cuantitativo por la naturaleza de las variables de estudio, es no experimental en su diseño y al hacer uso de las redes neuronales artificiales para el cálculo y predicción del rendimiento académico en función de los factores socioeconómicos es del tipo aplicada, utiliza un proceso inductivo para determinar los pesos y bias adecuadas de la red y así obtener el valor de salida correspondiente en cada caso, utilizando el 60% de datos históricos recopilados en fichas socioeconómicas para su entrenamiento y 40% para su evaluación.

Figura N° 1: Metodología de investigación



La investigación utiliza el método inductivo - deductivo, al partir de un conjunto de datos históricos de las variables que intervienen en el cálculo del rendimiento académico de los estudiantes, y es a través de una red neuronal backpropagation se obtiene un modelo que generaliza esta información para cada estudiante, y el aspecto deductivo corresponde al predecir el cálculo del rendimiento académico de los estudiantes que no fueron considerados en estos datos históricos.

La investigación es del tipo aplicada, donde se desarrolla la herramienta de las redes neuronales artificiales para determinar la incidencia de los factores socioeconómicos en el rendimiento académico de los estudiantes. Su diseño corresponde al tipo no experimental, dado a que se cuenta con una Red neuronal backpropagation que va a predecir los resultados y a comparar con los obtenidos en los datos históricos.

La población está conformada por 6022 estudiantes de los ciclos: 2020 – I y 2020 – II. El tamaño de la muestra fue 2979 estudiantes del ciclo 2020 – I y 2020 – II.

Se emplearon técnicas de observación, análisis documental y encuestas.

Observación, estuvo presente en algunas encuestas realizadas por el personal encargado de la aplicación de las fichas socioeconómicas. Encuestas online, mediante los registros de fichas virtuales permitirá recolectar información para los datos de entrada de la Red Neuronal permitiendo contar con una gran cantidad de datos para la construcción de la base de datos y el entrenamiento. Análisis documental, por medio del registro de consolidados de notas, facilitará el entrenamiento y evaluación de resultados esperados.

El procedimiento para la recolección de datos de la presente investigación será:

1. Se solicitó a las oficinas pertinentes las fichas socioeconómicas virtuales y los consolidados de notas de todos los estudiantes los ciclos 2020-I, 2020-II.
2. Se construyó la base de datos a partir de las fichas y consolidados de los estudiantes en los ciclos 2020-I, 2020-II.
3. Se depuró la base de datos buscando la dependencia de los mismos
4. Se desarrolló un algoritmo de aprendizaje profundo por medio de una red neuronal supervisada que nos va permitir evaluar el grado de aproximación con los valores deseados.




5. Se entrenó la red neuronal con el registro de datos de los estudiantes en las fichas socioeconómicas y los datos de promedios globales por ciclo de los consolidados de notas.
6. Se realizó la evaluación de la red neuronal.

RESULTADOS

El propósito de la investigación fue calcular el rendimiento académico de los estudiantes, mediante la determinación de los factores influyentes en dicha variable, para lo cual se construyó una red neuronal artificial supervisada que nos permitió evaluar el grado de aproximación de los valores obtenidos con los valores deseados, esto fue posible a partir del entrenamiento de la red neuronal con el registro de datos de los estudiantes en las fichas socioeconómicas y los datos de promedios globales por ciclo de los consolidados de notas, donde el algoritmo ajustó sus pesos y conexiones internas mediante un proceso iterativo, con el objetivo de minimizar el error entre las predicciones de la red y las etiquetas correctas.

Figura N° 2: Diagrama de la Red Neuronal Artificial Supervisada



Fuente: Elaboración Propia

El teorema de Kolmogorov (1957), junto con otros resultados como el teorema de aproximación universal (1991), fundamenta la idea de que las redes neuronales son aproximadores universales. Es decir, que una red neuronal suficientemente grande con capas ocultas adecuadas puede aproximar cualquier función continua con la precisión deseada.

El algoritmo de retropropagación (backpropagation) en su trabajo seminal de Rumelhart, Hinton y Williams (1986), logra que una red neuronal aprenda a partir de un conjunto de datos supervisados. Esto es, ajusta los pesos de las conexiones en la red para que pueda predecir las salidas correctas, minimizando el error.

En el entrenamiento de la red se consideró como base de datos las fichas socioeconómicas y los registros de notas de los estudiantes correspondientes a los semestres 2020-I y II. Tras la normalización y depuración de los datos recopilados, se utilizó un 60% de ellos para el entrenamiento y el 40% restante para la validación, el algoritmo comienza con la propagación hacia adelante, en la cual los datos de entrada pasan por la red hasta llegar a la capa de salida, produciendo una predicción. Luego, se calcula el error (o diferencia) entre la predicción y la salida deseada. Después de eso, la retropropagación ocurre. Se calcula cómo los errores de la salida afectan a cada una de las neuronas en las capas ocultas, comenzando desde la capa de salida hacia atrás a las capas anteriores (de ahí el nombre "retropropagación"). La idea es distribuir este error hacia atrás a través de la red, ajustando los pesos y las bias en cada capa para reducir el error en futuras iteraciones.

La arquitectura básica de una red neuronal supervisada consiste en capas de neuronas (o nodos) organizadas en una capa de entrada, una o más capas ocultas y una capa de salida. Las neuronas están conectadas entre sí por medio de pesos y bias, y en cada neurona se aplica una función de activación para determinar su salida.

El diseño de la red neuronal supervisada para determinar la incidencia de los factores socioeconómicos en el rendimiento académico de los estudiantes es del tipo Feed-forward backpropagation, con 6 variables de entrada que representan a los factores socioeconómicos, 2 capas ocultas con 6 y 3 neuronas respectivamente, y una capa de salida con 1 neurona que muestra el rendimiento académico de los estudiantes.

Como se observa a continuación:

Matrices de entrada, de pesos y bias en la primera capa oculta.



$$X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \end{bmatrix}_{6 \times 1} ; W_1 = \begin{bmatrix} w_{1,1}^{(1)} & w_{1,2}^{(1)} & w_{1,3}^{(1)} & w_{1,4}^{(1)} & w_{1,5}^{(1)} & w_{1,6}^{(1)} \\ w_{2,1}^{(1)} & w_{2,2}^{(1)} & w_{2,3}^{(1)} & w_{2,4}^{(1)} & w_{2,5}^{(1)} & w_{2,6}^{(1)} \\ w_{3,1}^{(1)} & w_{3,2}^{(1)} & w_{3,3}^{(1)} & w_{3,4}^{(1)} & w_{3,5}^{(1)} & w_{3,6}^{(1)} \\ w_{4,1}^{(1)} & w_{4,2}^{(1)} & w_{4,3}^{(1)} & w_{4,4}^{(1)} & w_{4,5}^{(1)} & w_{4,6}^{(1)} \\ w_{5,1}^{(1)} & w_{5,2}^{(1)} & w_{5,3}^{(1)} & w_{5,4}^{(1)} & w_{5,5}^{(1)} & w_{5,6}^{(1)} \\ w_{6,1}^{(1)} & w_{6,2}^{(1)} & w_{6,3}^{(1)} & w_{6,4}^{(1)} & w_{6,5}^{(1)} & w_{6,6}^{(1)} \end{bmatrix}_{6 \times 6} ; b_1 = \begin{bmatrix} b_1^{(1)} \\ b_2^{(1)} \\ b_3^{(1)} \\ b_4^{(1)} \\ b_5^{(1)} \\ b_6^{(1)} \end{bmatrix}_{6 \times 1} ; a_1 = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \\ a_3^{(1)} \\ a_4^{(1)} \\ a_5^{(1)} \\ a_6^{(1)} \end{bmatrix}_{6 \times 1}$$

Aplicación de la función de activación en la primera capa oculta, propagación hacia adelante.

$$v_1 = W_1 * X + b_1 ; a_1 = \varphi(v_1) \text{ salida}$$

$$a_i^{(1)} = \varphi \left(w_{i1}^{(1)} x_1 + w_{i2}^{(1)} x_2 + w_{i3}^{(1)} x_3 + w_{i4}^{(1)} x_4 + w_{i5}^{(1)} x_5 + w_{i6}^{(1)} x_6 + b_i^{(1)} \right)$$

Para $i = 1, 2, 3, 4, 5, 6$

Función de activación

$$\varphi(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

Matrices de entrada, de pesos y bias en la segunda capa oculta.

$$a_1 = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \\ a_3^{(1)} \\ a_4^{(1)} \\ a_5^{(1)} \\ a_6^{(1)} \end{bmatrix}_{6 \times 1} ; W_2 = \begin{bmatrix} w_{1,1}^{(2)} & w_{1,2}^{(2)} & w_{1,3}^{(2)} & w_{1,4}^{(2)} & w_{1,5}^{(2)} & w_{1,6}^{(2)} \\ w_{2,1}^{(2)} & w_{2,2}^{(2)} & w_{2,3}^{(2)} & w_{2,4}^{(2)} & w_{2,5}^{(2)} & w_{2,6}^{(2)} \\ w_{3,1}^{(2)} & w_{3,2}^{(2)} & w_{3,3}^{(2)} & w_{3,4}^{(2)} & w_{3,5}^{(2)} & w_{3,6}^{(2)} \end{bmatrix}_{3 \times 6} ; b_2 = \begin{bmatrix} b_1^{(2)} \\ b_2^{(2)} \\ b_3^{(2)} \end{bmatrix}_{3 \times 1} ; a_2 = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \\ a_3^{(2)} \end{bmatrix}_{3 \times 1}$$

Aplicación de la función de activación en la segunda capa oculta, propagación hacia adelante.

$$v_2 = W_2 * a_1 + b_2 ; a_2 = \varphi(v_2) \text{ salida}$$

$$a_i^{(2)} = \varphi \left(w_{i1}^{(2)} a_1^{(1)} + w_{i2}^{(2)} a_2^{(1)} + w_{i3}^{(2)} a_3^{(1)} + w_{i4}^{(2)} a_4^{(1)} + w_{i5}^{(2)} a_5^{(1)} + w_{i6}^{(2)} a_6^{(1)} + b_i^{(2)} \right)$$

Para $i = 1, 2, 3$

Función de activación

$$\varphi(x) = \frac{2}{1 + e^{(-2x)}} - 1$$



Matrices de entrada, de pesos y bias en la capa de salida.

$$a_2 = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \\ a_3^{(2)} \end{bmatrix}_{3 \times 1}; W_3 = [w_{1,1}^{(3)} \ w_{1,2}^{(3)} \ w_{1,3}^{(3)}]_{1 \times 3}; b_3 = [b_1^{(3)}]_{1 \times 1}; y = [a_1^{(3)}]_{1 \times 1}$$

Aplicación de la función de activación en la capa de salida, propagación hacia adelante.

$$v_3 = W_3 * a_2 + b_3 ; y = \varphi(v_3) \text{ salida(promedio)}$$

$$y = a_1^{(3)} = \varphi \left(w_{11}^{(3)} a_1^{(2)} + w_{12}^{(3)} a_2^{(2)} + w_{13}^{(3)} a_3^{(2)} + b_1^{(3)} \right)$$

Función de activación

$$\varphi(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

El aprendizaje en la Red Neuronal se dá en la modificación de los pesos y bias iniciales, mediante el incremento de la razón de cambio de la función error respecto a cada peso y bias, este proceso recibe el nombre de propagación hacia atrás.

Función error(E) y error relativo(e)

$$E = \frac{1}{2}(s_1 - y)^2 ; e = s_1 - y$$

Donde s_1 es el valor deseado y y es el valor obtenido

Propagación hacia atrás en los pesos y bias


$$W_i = W_i + \alpha \cdot e \cdot \frac{\partial y}{\partial W_i} \quad i = 1,2,3, \quad \alpha : \text{tasa de aprendizaje}$$

El algoritmo para ajustar los pesos y bias de la red, utiliza el método de $b_i^j = b_i^j + \alpha \cdot e \cdot \frac{\partial y}{\partial b_i^j}$

Levenberg-Marquardt implementada en la herramienta nntool de Matlab. Es decir, calcula el gradiente del error respecto a cada peso, y luego ajustar los pesos en la dirección opuesta a ese gradiente para reducir el error.

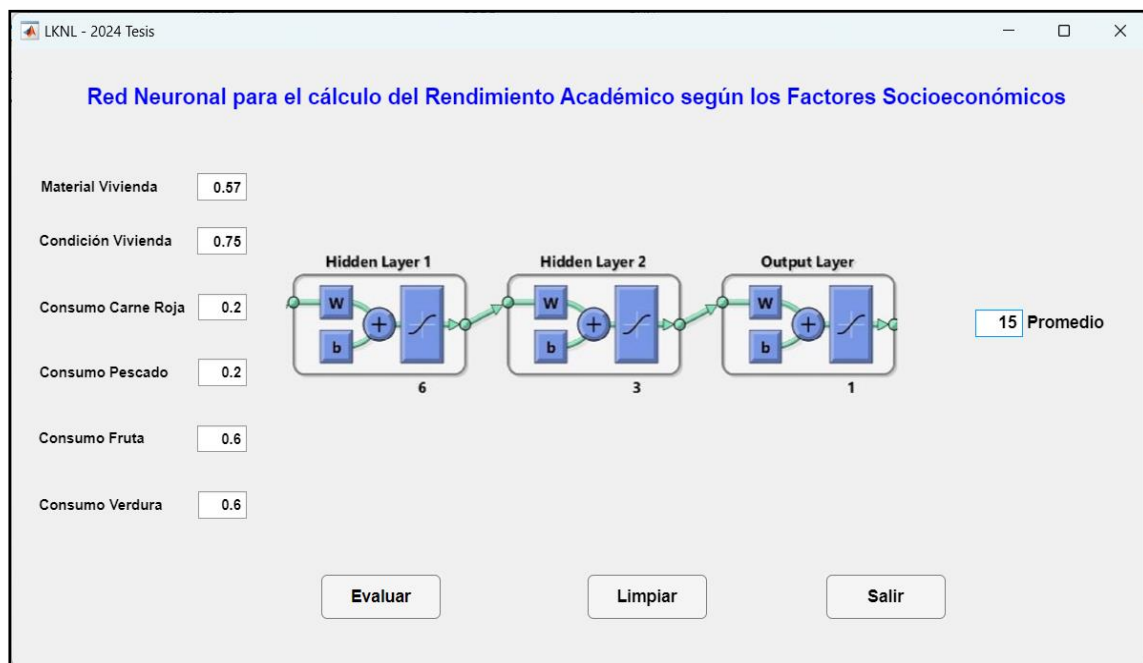


Figura N° 3: Diagrama de la Red Neuronal Artificial Supervisada



Fuente: Elaboración Propia

Figura N° 4: Evaluación del Sistema de la Red Neuronal Artificial Supervisada



Fuente: Elaboración Propia

Los componentes de la interfaz gráfica están compuestos por diversos componentes: etiquetas que muestran los nombres, cuadros de texto que aceptan únicamente datos normalizados en el rango de [0 – 1], y una imagen que ilustra las capas de entrada, oculta y salida, además de cómo funciona internamente cada neurona.

También incluye un cuadro de texto que muestra el promedio del estudiante en formato vigesimal. Finalmente, hay tres botones que permiten programar la evaluación de las variables de entrada, limpiar las casillas y cerrar el sistema.

DISCUSIÓN

El presente trabajo es coincidente con Kolmogorov (1957), y el teorema de aproximación universal (1991), que fundamenta la idea de que las redes neuronales son aproximadores universales.

Las variables de entrada se seleccionaron para evaluar su impacto en el rendimiento académico, considerando ocho aspectos clave de la ficha socioeconómica. Los resultados obtenidos muestran una correlación con los hallazgos de Espada, Rocu, Navia y Gómez (2020), lo que sugiere una consistencia en la influencia de estos factores socioeconómicos.

La implementación de la red neuronal utilizando la librería `nnTool` de Matlab logró un alto porcentaje de aciertos en la predicción del rendimiento académico, resultados que son comparables a los obtenidos por Estela y Capuñay (2023) mediante el uso del algoritmo de Levenberg-Marquardt. Este método de optimización, ampliamente utilizado en el entrenamiento de redes neuronales artificiales para problemas de regresión no lineal, demostró su eficacia en este contexto.

Al profundizar en los datos, se observaron diferencias significativas en la recopilación de información entre los semestres 2020-I y II. La muestra inicial de 6022 estudiantes fue depurada y estructurada, resultando en un conjunto de datos de 2979 estudiantes aptos para la aplicación del algoritmo de Levenberg-Marquardt. Este enfoque cuantitativo, alineado con la metodología de Brand, Uribe y Valencia (2023), se caracteriza por el uso de grandes volúmenes de datos estructurados que permiten analizar matemáticamente las relaciones entre variables, generando modelos predictivos capaces de aprender patrones complejos y generalizar eficazmente.

Se identificaron discrepancias con los resultados obtenidos por Bedoya, Guarín y Agudelo (2023), donde la escasez de variables de entrada en su aplicación de redes neuronales artificiales resultó en un nivel de satisfacción inferior.

En lo que respecta al cálculo del rendimiento académico, los resultados obtenidos mediante el método de optimización utilizado en este estudio fueron altamente satisfactorios. Este método, que combina características del Método de Gauss-Newton y el Método de Descenso del Gradiente, permite un ajuste



eficiente de los pesos en la red neuronal. Este enfoque mostró similitudes con los resultados de Çetinkaya y Kaan (2020), quienes destacaron la capacidad de los algoritmos ANN para predecir de manera válida y eficiente la aptitud en programación.

Finalmente, el algoritmo de Levenberg-Marquardt, diseñado para resolver problemas de optimización no lineales, demostró ser especialmente útil para minimizar la función de error en redes neuronales. Al cambiar dinámicamente entre el Método de Gauss-Newton y el Descenso del Gradiente, según la proximidad a la solución óptima, el algoritmo optimiza los parámetros de la red con gran efectividad. Este enfoque ha mostrado coincidencias significativas con los hallazgos de Quintana, Flores, Lazcano y Landassuri (2018) en su trabajo sobre ensamblaje de clasificadores utilizando redes neuronales artificiales.

CONCLUSIONES

La presente investigación nos permitió:

Calcular el Rendimiento Académico de los estudiantes de la Universidad Nacional del Santa en función de los Factores Socioeconómicos en el semestre 2020 I y II, mediante un proceso inductivo en una red neuronal supervisada del tipo Feed-forward backpropagation.

Determinar la incidencia de los factores socioeconómicos en el rendimiento académico de los estudiantes mediante el diseño de una red con 6 variables de entrada que representan a los factores socioeconómicos, 2 capas ocultas con 6 y 3 neuronas respectivamente, y una capa de salida con 1 neurona que muestra el rendimiento académico de los estudiantes.

Entrenar la red neuronal supervisada con 1,787 datos normalizados en un rango de [0 - 1], y que representa el 60 % de datos de la muestra, a través del algoritmo de Levenberg – Marquardt, y con funciones de activación del tipo tansig.

Evaluar la red neuronal supervisada con 1192 datos normalizados en un rango de [0 - 1] y que representa el 40 % de datos de la muestra, para determinar el rendimiento académico de los estudiantes de la UNS, con las matrices de pesos y bias obtenidas en la etapa del entrenamiento.

del análisis de los errores se concluyó como no significativo y que se puede minimizar adicionando capas y el número de neuronas a la Red Neuronal.



REFERENCIAS BIBLIOGRAFICAS

- Basogain Olabe, X. (1998). Redes Neuronales Artificiales y sus Aplicaciones. Madrid: Publicaciones de la Escuela de Ingenieros.
- Blake, P., & Wadhwa, D. (12 de 2020). Crupo Banco Mundial. Obtenido de Banco Mundial Blogs: <https://blogs.worldbank.org/es/voices/resumen-anual-2020-el-impacto-de-la-covid-19-coronavirus-en-12-graficos>
- Carrión Pérez, E. (2007). Validación de Características al Ingreso como Predictores del Rendimiento Académico en la Carrera de Medicina. Revista Cubana de Educación Médica Superior, 1(16).
- Castejón, J., & Pérez, A. (1998). Un Modelo Causal - Explicativo de las variables Psicosociales en el Rendimiento Académico. Revista Bordón, 50(2), 171-185.
- Choi de Mendizábal, Á. B. (2018). Fundación "La Caixa". Obtenido de El Observatorio Social: <https://observatoriosociallacaixa.org/-/desigualdades-socioeconomicas-y-rendimiento-academico>
- Durón, T., & Oropeza, T. (1999). Análisis Predictivo a partir de la Interacción Familiar y Escolar de Estudiantes de Nivel Superior. Universidad Nacional Autónoma de México, México.
- Espada, M., Rocu, P., Navia, J., & Gómez, M. (2020). Rendimiento Académico y Satisfacción de los Estudiantes Universitarios hacia el Método Flipped Classroom. Profesorado, Revista del Curriculum y Formación del Profesorado, 116-135.
- Gallo, C. (2021). Estrategias didácticas y el rendimiento académico en los estudiantes de la Escuela de Ingeniería. Revista Peruana de Educación, 37-48.
- Gonzales, E., & Evaristo, I. (2021). Rendimiento académico y deserción de estudiantes universitarios de un curso en modalidad virtual y presencial. Revista Iberoamericana de Educación a Distancia, 189-198. Obtenido de <https://www.redalyc.org/articulo.oa?id=331466109011>
- Pérez Luño, A., Ramón Jerónimo, J., & Sánchez Vásquez, J. (2000). Análisis Exploratorio de las Variables que Condicionan el Rendimiento Académico. Sevilla, España: Universidad Pablo de Olavide.



- Quintana, M., Flores, J., Lazcano, S., & Landassuri, V. (2018). Ensamble de Clasificadores para Determinar el Perfil Académico del Estudiante usando Árboles de Decisión y Redes Neuronales. *ResearchGate*, 255-267.
- Rodríguez, S., Fita, S., & Torrado, M. (2004). El Rendimiento Académico en la Transición Secundaria-Universidad. *Revista de Educación. Temas Actuales de Enseñanza*, 334.
- Romero, J., Aznar, I., Hinojo, F., & Gómez, G. (2020). Uso de los dispositivos móviles en educación superior: relación con el rendimiento académico y la autorregulación del aprendizaje. *Revista Complutense de Educación*, 327-335.
- Torres, S., Aldana, M. P., & Piedra, L. (2016). Red Neuronal Multicapa para la Evaluación de Competencias Laborales. *Revista Cubana de Ciencias Informáticas*, 210-223.
- Valle Arias, A., González Cabanach, R., Núñez Pérez, J., & Martínez Rodríguez, S. (1999). Un Modelo Causal sobre los Determinantes cognitivo - Motivacionales del Rendimiento Académico. *Revista de Psicología General Aplicada*, 52(4), 499-519.
- Vélez Van, M., & Roa, N. (2005). Factors Associated with Academic Performance in Medical Students. *PSIC. Educación Médica*, 1-10.
- Vemuri, V. (1990). *Artificial Neural Networks: Theoretical Concepts* Computer Society Press. Los Alamitos C.A.
- Viñuela, P., & León, I. (2004). *Redes Neuronales Artificiales: Un Enfoque Práctico*. Madrid: Editorial Pearson Prentice Hall.

