



Predicción de resultados académicos con la aplicación nntool en Matlab utilizando redes neuronales artificiales

Prediction of academic results with the nntool application in Matlab using artificial neural networks

Dulce Lucero Capuñay Sanchez,¹¹ Fernando Alain Incio Flores,² Ronald Omar Estela Urbina,³ Luis Montenegro Camacho,⁴ Jorge Antonio Delgado Soto,⁵ Johnny Cueva Valdivia⁶

Universidad Cesar Vallejo, Lima, Perú¹⁴

Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Perú²³

Universidad Nacional de Cajamarca, Cajamarca, Perú⁵

Universidad Nacional Santiago Antúnez de Mayolo, Ancash, Perú⁶

 ORCID ID: <https://orcid.org/0000-0001-8678-5766>¹

 ORCID ID: <https://orcid.org/0000-0003-3286-7787>²

 ORCID ID: <https://orcid.org/0000-0001-5240-1242>³

 ORCID ID: <https://orcid.org/0000-0002-8696-5203>⁴

 ORCID ID: <https://orcid.org/0000-0003-2275-8608>⁵

 ORCID ID: <https://orcid.org/0000-0001-8167-109X>⁶

Recibido: 20 de junio de 2021

Aceptado: 15 de octubre de 2021

Resumen

En el 2018, Perú participó de la Evaluación Internacional de Estudiantes (PISA), donde se evidenciaron resultados desalentadores en los estudiantes de educación básica regular. En tal sentido, se consideró la predicción de resultados académicos como un instrumento de mejora del rendimiento escolar. El objetivo de esta investigación fue predecir el promedio anual de estudiantes del segundo grado de la Institución Educativa N°16093 en la provincia de Jaén-Perú, mediante el diseño e implementación de una red neuronal artificial (RNA). Para la recolección de datos de las variables que influyen en el promedio anual del estudiante, se elaboró un cuestionario de respuestas dicotómicas. En la validación y confiabilidad, se utilizó el criterio de juicio de expertos y la prueba Kuder-Richarson respectivamente, en el cual el coeficiente de confiabilidad obtenido en una prueba piloto aplicado a 15 estudiantes fue de 0.8359. En el software científico Matlab con la ayuda de la aplicación *nntool*, se diseñó la RNA formada por tres capas ocultas y una capa de salida. La RNA durante el entrenamiento, la validación y la prueba, registró un coeficiente de correlación ponderado de 0.967190, y un error cuadrático medio de 0.05011. El modelo neuronal implementado bajo las condiciones dadas logró una efectividad del 88.670% y 98.522%.

¹Correspondencia al autor:
E-mail: dcapunay@ucvvirtual.edu.pe

Palabras clave: Rendimiento académico, nntool, redes neuronales artificiales, predicción, educación.

Abstract

In 2018, Peru participated in the International Student Assessment (PISA), where disappointing results were evidenced in students of regular basic education. In this sense, the prediction of academic results was considered as an instrument for improving school performance. The objective of this research was to predict the annual average of second grade students of the Educational Institution N ° 16093 in the province of Jaén-Peru, through the design and implementation of an artificial neural network (ANN). To collect data on variables that influence the annual average of the student, a questionnaire with dichotomous responses was developed. In the validation and reliability, we used the expert judgment criterion and the Kuder-Richarson test respectively, the reliability coefficient obtained in a pilot test applied to 15 students was 0.8359. In the Matlab Scientific Software with the help of the nntool application, the RNA was designed consisting of three hidden layers and an output layer. The ANN during training, validation and testing, registered a weighted correlation coefficient of 0.967190, and a mean square error of 0.05011. The neural model implemented under the given conditions achieved an effectiveness of 88.670% and 98.522%.

Keywords: Academic performance, nntool, artificial neural networks, prediction, education.

Introducción

Predecir los resultados académicos de los estudiantes de manera temprana, permite al docente, tomar las medidas correctivas y necesarias en la búsqueda de estrategias a fin de mejorar el logro de competencias en sus estudiantes. En el Perú, el actual diseño curricular nacional que el Ministerio de Educación ha elaborado, está fundamentado en el logro de competencias. Una competencia es la destreza que adquiere el estudiante para combinar conocimientos, actitudes, aptitudes y habilidades para dar solución a una situación problemática en un tiempo determinado (Echeverría-Ramírez & Mazzitelli, 2021; Hernández, 2018; Incio & Capuñay, 2020; Olascoaga, 2020; Sagredo et al., 2021). Bajo este concepto, se entiende al rendimiento académico, como el sistema que mide el logro de competencias en una escala vigesimal, expresada en el promedio final del estudiante en determinadas materias académicas durante un periodo de estudios (Comella et al., 2021; Criollo et al., 2017; González-García et al., 2019; González-Velasco et al., 2021; Rodríguez et al., 2021). Por ello, la formación académica del estudiante de educación básica, es consecuencia de la combinación de una serie de factores de carácter endógeno y exógeno que lo rodea, diversos autores agrupan a estos agentes influyentes del rendimiento académico de acuerdo a sus funcionalidades: de orden personal, social e institucional (Ferraces et al., 2021; Pizarro et al., 2021; Porras & Ortega, 2021).

Por otro lado, una RNA es un modelo matemático y computacional, diseñado para aprender mediante el entrenamiento, valiéndose de un conjunto de datos de entrada que le permiten su aprendizaje a través un conjunto de neuronas artificiales interconectadas entre sí, por medio de funciones matemáticas de activación, el cual simula el comportamiento del cerebro humano: aprender mediante la experiencia (Barreto & Picón, 2020; da Silva et al., 2020; Goyes-Peñafiel & Hernandez-Rojas, 2021; Pal & Chakrabarty, 2020; Şenyurt et al., 2020). Entre los tipos de redes neuronales artificiales más conocidas tenemos al Perceptrón simple y Perceptron multicapa, Adaline, Redes de Feed-Forward, Redes de Elman, Redes de Hopfield. En esta investigación, y de acuerdo a la naturaleza de los datos, se ha utilizado las Redes de Feed-Forward, las cuales se caracterizan por la flexibilidad en la implementación en el número de capas ocultas y el número de neuronas en cada capa según los resultados en cada prueba. Diversas investigaciones sustentan que las Redes de Feed-Forward superan las limitaciones que presentan los tipos de redes neuronales anteriormente mencionadas en cuanto a su estructura y procesamiento de la data (Figueroa-Garcia et al., 2021; Incio et al., 2021; H. E. D. Rodríguez et al., 2021; Sosa et al., 2021; Wingerter et al., 2020).

Las investigaciones destacan la importancia de las redes neuronales artificiales en la predicción en el campo de la educación; en el contexto internacional, Martins et al. (2020) realizaron una investigación para predecir la deserción estudiantil, apoyándose en algoritmos de minería de datos como árboles de decisión y redes neuronales artificiales; lograron implementar modelos neuronales para predecir la deserción escolar universitaria, logrando de esta manera que los docentes responsables de cada asignatura adopten medidas y decisiones estratégicas para reducir la tasa de abandono de estudios al culminar el periodo académico (Costa et al., 2017). En este caso, Lejía et al. (2010) realizaron una investigación para predecir el rendimiento en matemáticas de estudiantes pre universitarios, para lograr su objetivo trabajaron redes neuronales con algoritmos de retro propagación y regresión generalizada, mediante una validación cruzada de 10 veces logró identificar que el mejor modelo de predicción es el implementado con el algoritmo de retro propagación con una efectividad de precisión del 66.67% y 71.11%.

En Turquía Çetinkaya y Baykan (2020) en su investigación basada en redes neuronales artificiales implementaron un modelo neuronal para predecir el talento en programación en estudiantes de secundaria, la RNA fue implementada en Matlab con la aplicación *nnstart* mediante regularización bayesiana, gradiente conjugado y el algoritmo Levenberg Marquardt, tomando datos históricos y apoyado en un curso implementado en la plataforma Code.org logró predecir y comparar la efectividad en la predicción, el modelo neuronal implementado con

mayor efectividad fue mediante el algoritmo Levenberg Marquardt. En la República de Cuba, Álvarez et al. (2016) diseñaron e implementaron un modelo de RNA con una capa de entrada oculta y de salida para predecir el rendimiento académico de estudiantes de educación superior en los curso de Estructuras de Datos I y II, el modelo implementado en Matlab logró una efectividad de predicción del 78% y 75% respectivamente en cada curso.

En el contexto nacional en la Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Incio et al. (2021) realizaron una investigación para predecir el rendimiento académico en estudiantes universitarios de la carrera de Ingeniería Civil en el curso de Física, aprovechando los algoritmos implementados en la Toolbox de Matlab: Scaled Conjugate Gradient y Levenberg Marquardt, implementaron dos redes neuronales con una capa de entrada, una capa oculta y una capa de salida, los resultados muestran que el algoritmo que logró mayor efectividad en el predicción fue el Levenberg Marquardt (86%) , mientras que el Scaled Conjugate Gradient (70%). En la Universidad Agraria la Molina, Menacho (2017) empleando diagramas de árbol de decisión, redes neuronales y redes bayesianas logró implementar un modelo neuronal con una efectividad del 71% para predecir los resultados académicos del curso de Estadística General.

Por tanto, el objetivo de la investigación fue diseñar e implementar un modelo de red neuronal artificial mediante la aplicación nntool en el software científico Matlab, a fin de predecir el rendimiento académico de los estudiantes del segundo grado de la Institución Educativa N°16093 en la provincia de Jaén-Perú.

Materiales y métodos

En esta investigación se pretendió recolectar la percepción de todos los estudiantes del tercer, cuarto y quinto grado de educación secundaria de la Institución Educativa N°16093 con respecto a las variables que influyen en el rendimiento académico, siendo en su totalidad 235 estudiantes; sin embargo—y debido a la coyuntura actual por la que atraviesa la educación virtual en Perú como consecuencia del Covid-19 y los múltiples obstáculos que esta presenta, entre ellos la conectividad—solamente se ha logrado recolectar datos de 203 estudiantes. Los datos recolectados en esta investigación están relacionados con los factores de índole personal, social e institucional que influyen significativamente en el rendimiento académico del estudiante de secundaria, para la elaboración del instrumento de recolección de datos (cuestionario) se realizó un trabajo previo de revisión bibliográfica (Ferraces et al., 2021; Pizarro et al., 2021; Ramos & Gómez, 2021), luego se elaboró el cuestionario con 45 preguntas de respuestas dicotómicas; las preguntas del 1-19 están referidas a los factores personales, del

20-30 a los factores sociales y del 31-45 a factores institucionales, para la validación del instrumento se empleó el criterio de juicio de expertos y para la confiabilidad la prueba Kuder-Richardson (KR_{20}) aplicado a un piloto de 15 estudiantes (Díaz-Muñoz, 2020), siendo el coeficiente de confiabilidad obtenido de 0.8359 el cual es calificado como bueno (Foster, 2020, 2021).

El mencionado cuestionario fue elaborado con la aplicación Google Forms y enviado a los estudiantes por medio de un enlace WhatsApp, correo electrónico o en su defecto mediante llamada telefónica, garantizando en todo momento la confidencialidad de la información brindada por los estudiantes encuestados, el respeto estricto a la normativa de la institución educativa y la no manipulación de la data obtenida. Una vez aplicado el cuestionario, se descargó un archivo Excel generado por la aplicación conteniendo la percepción de los estudiantes respecto a las variables que influyen en el rendimiento académico. Asimismo, se utilizó el diseño metodológico CRISP-DM, según International Business Machines Corporation (2021) es el modelo que mejor se adapta a investigaciones que involucren minería de datos y redes neuronales artificiales.




Figura 1. International Business Machines Corporation

La evaluación del modelo de red neuronal implementado en Matlab 2016a se realizó teniendo en cuenta el coeficiente de correlación (R) y el error cuadrático medio (MSE, por sus siglas en Inglés).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{ic} - y_{im})^2}{\sum_{i=1}^n (y_{ic} - y_m)^2} \quad y \quad MSE = \frac{1}{n} \sum_{i=1}^n (y_{ic} - y_{im})^2$$

Donde “n” es el número de observaciones, y_{ic} es el i-ésimo valor calculado, y_{im} es el i-ésimo valor medido, finalmente y_m es el valor medio de los valores calculados. La presente investigación se realizó cumpliendo la normativa interna de la Institución Educativa José Gálvez N°16093 de Chunchuquillo. En este sentido y respetando los valores que todo profesional debe cultivar, los datos se recolectaron con el consentimiento de los estudiantes y padres de familia, comprometiéndonos a guardar la confidencialidad respectiva.

Resultados

La red neuronal artificial *Feed-Forwad Backpropagation* implementada en la Toolbox de Matlab nos facilitó opciones para elegir las funciones de entrenamiento, aprendizaje, desempeño y transferencia, así como también designar el número de capas y el número de neuronas en cada capa, las variables de entrada de la RNA fueron los datos de los estudiantes recolectados mediante el cuestionario, la variable de salida es el promedio anual del estudiante redondeado al entero más cercano. Después de realizar numerosos intentos evaluando los modelos neuronales diseñados teniendo en cuenta la efectividad en la predicción, la Tabla 1 muestra las características del tipo RNA con mayor efectividad de predicción.

Tabla 1

Características de RNA implementada con mayor efectividad de predicción

Red neuronal artificial	Característica
Tipo de red	Feed-Forwad Backpropagation
Función-entrenamiento	Levenberg Marquardt
Función-aprendizaje	Descenso del gradiente
Función-desempeño	Error cuadrático medio
Función-transferencia	Sigmoidea tangente hiperbólica
Neuronas que posee la primera capa oculta	38
Neuronas que posee la segunda capa oculta	18
Neuronas que posee la tercera capa oculta	16
Neuronas que posee la única capa de salida	1

Nota. El tipo de función y el número de neuronas fueron seleccionados buscando un mejor ajuste del modelo de RNA.

La arquitectura de esta RNA que se ha diseñado teniendo en cuenta el número de neuronas en cada capa está ilustrado en la Figura 2, se aprecia 38-18-16 neuronas en la primera, segunda y tercera capa oculta, la capa de salida presenta una sola neurona. Input (entrada de la RNA, datos del estudiante). Output (salida de la RNA, promedio anual del estudiante redondeado al entero más cercano).




Figura 2. Arquitectura de la RNA implementada en Matlab 2016a. Gráfica obtenida en el Software Matlab 2016a.

Después de realizar distintas pruebas y evaluar cada modelo de RNA mediante el R y MSE (en cada modelo se efectuaron 10 corridas), la red neuronal implementada con las características de la Tabla 1 logró un R y MSE tal como se detalla en la Tabla 2.

Tabla 2

Coefficiente de correlación y error cuadrático medio

Tipo de Red	Coeficiente de correlación			Coeficiente de correlación ponderado	Error cuadrático medio
	Entrenamiento	Validación	Prueba		
Feed-Forwad Backpropagation	0.989110	0.925220	0.890730	0.967190	0.05011

Nota. Valores obtenidos en el Software Matlab 2016a en la octava iteración

La Figura 3 muestra el coeficiente de correlación en cada etapa, permite visualizar la relación que existe entre el promedio obtenido (real) y el promedio esperado (real) del estudiante. Training (entrenamiento), Validation (validación), Test (prueba).




Figura 3. Coeficiente de correlación en cada etapa.

Gráfica obtenida en el Software Matlab 2016a.

En cuanto al error cuadrático medio, la Figura 4 muestra una disminución notable del error mientras la RNA ejecuta cada una de sus procesos. En la segunda iteración se observa un MSE de 0.21385, seguidamente en la octava iteración el MSE disminuye a 0.05011.




Figura 4. Error cuadrático medio. Gráfica obtenida en el Software Matlab 2016a

La Tabla 3 muestra la predicción del promedio anual de los 203 estudiantes (E001,E002,.....,E203) que ya cursaron el segundo grado de educación secundaria de la Institución Educativa N°16093 mediante el modelo de red neuronal implementado con las características descritas anteriormente en la Tabla 1 y Tabla 2.

Tabla 3

Predicción del promedio anual de estudiantes del tercer al quinto grado de secundaria

Participantes	Promedio final real	Predicción de la RNA
E001	16	16
E002	15	14
E003	16	16
E004	14	14
E005	15	15
E006	15	15
E007	14	14
E008	15	14
E009	15	16
E010	19	19
E011	15	15
E012	16	16
E013	14	14
E014	16	16
E015	15	15
E016	17	17
E017	0	1
E018	17	17
E019	17	17
E020	14	14
E021	17	17
E022	14	14
E023	16	16
E024	16	16
E025	14	14
E026	19	19
E027	10	10
E028	17	16
E029	15	15
E030	17	17
E031	16	16
E032	17	17
E033	17	17
E034	16	16
E035	15	15
E036	18	18
E037	16	16
E038	15	16
E039	17	17
E040	16	16
E041	15	15
E042	15	15

E043	15	17
E044	18	18
E045	18	18
E155	18	18
E156	16	16
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
E160	17	17
E161	15	15
E162	17	17
E163	14	14
E164	16	16
E165	15	15
E166	16	16
E167	14	14
E168	14	14
E169	14	14
E170	14	14
E171	15	15
E172	14	14
E173	15	15
E174	17	17
E175	14	14
E176	15	15
E177	16	16
E178	14	14
E179	16	16
E180	18	18
E181	17	16
E182	14	15
E183	16	16
E184	13	13
E185	16	16
E186	15	15
E187	16	16
E188	16	16
E189	16	16
E190	17	17
E191	17	17
E192	14	14
E193	17	17
E194	14	14
E195	16	16
E196	15	16
E197	15	15
E198	19	19
E199	11	11

E200	16	16
E201	15	15
E202	16	17
E203	15	15

Nota. Se visualiza una efectividad del 88.670% en la predicción exacta del promedio redondeado al entero más cercano, la efectividad de predicción aumenta a 98.522% del promedio con una diferencias ± 1 del mismo.

Garantizada la efectividad en la predicción de la RNA, se aplicó el mismo cuestionario a 18 estudiantes que cursan actualmente el segundo grado de secundaria de la I.E. N°16093 con la finalidad de pronosticar sus promedios anuales correspondientes, la Tabla 4 muestra los resultados de esta predicción.

Tabla 4

Predicción del promedio de estudiantes del segundo grado de secundaria

Participantes	Promedio final real	Pronóstico de la RNA
E01		15
E02		17
E03		10
E04		17
E05		17
E06		14
E07		17
E08		14
E09		16
E10		16
E11		14
E12		19
E13		10
E14		16
E15		15
E16		17
E17		16
E18		17

Nota. Se visualiza la predicción del promedio de 18 estudiantes por medio del modelo de RNA implementado, las variables de entrada de la RNA son recolectadas con el mismo cuestionario aplicado anteriormente a los 203 estudiantes.

En la Figura 5 se visualiza el modelado de los resultados académicos de los estudiantes: Promedio final real (promedio esperado, Tabla 3), promedio producto de la predicción de la RNA implementada (promedio obtenido, Tabla 3) y el pronóstico (Tabla 4) del promedio de 18 estudiantes por medio de la RNA con las condiciones dadas en la Tabla 1 y la Tabla 2.




Figura 5. Modelado de resultados académicos

Discusión

Los resultados obtenidos en esta investigación confirman las afirmaciones dadas por Costa et al. (2017) y Lejía et al. (2010) al resaltar la efectividad en la predicción de resultados académicos que logran las redes neuronales artificiales. Ellos también concuerdan con la efectividad lograda en la predicción al igual que la RNA implementada por Çetinkaya y Baykan (2020) e Incio et al. (2021); sin embargo, se destacan dos situaciones muy importantes y diferentes: 1) ambas investigaciones utilizaron la aplicación *nstart* de Matlab logrando los mejores porcentajes de predicción (78%, 75%) con el algoritmo Levenberg Marquardt; no obstante, en nuestra investigación se utilizó la aplicación *nntool* de Matlab para diseñar la arquitectura de la RNA, la ventaja de esta última es la flexibilidad que se tiene con respecto a la designación del número de capas, número de neuronas en cada capa, y las respectivas funciones de activación; por lo que se logró una efectividad en la predicción del 88.670% y 98.522% en el promedio anual del estudiante (Tabla 2); 2) Çetinkaya y Baykan (2020) consideraron como una de las variables que le permitía predecir el talento en programación de los estudiantes, a las calificaciones de un curso en Code.org que implementaron de forma presencial, desventaja que nosotros al igual que Incio et al. (2021) tuvimos, puesto que la actual coyuntura sanitaria a causa del Covid-19 lo impide.

La fortaleza del modelo neuronal que se diseñó e implementó en esta investigación radica en la efectividad de predicción que posee, se ha logrado porcentajes predictivos muy altos comparados con las investigaciones citadas en este artículo, este logro se debe al tipo de red que se utilizó, a las funciones de activación escogidas y al número de neuronas que a cada capa se le asignó en las múltiples iteraciones que se realizaron, a pesar de que el tipo de red

neuronal *Feed-forward* se caracteriza por la efectividad en la predicción y facilidad en la implementación de su arquitectura, no debemos olvidar las características de la data con que se trabaja; en este sentido concordamos con lo afirmado por Wunderlich y Pehle (2021), Johnson et al. (2021) y Sabir et al (2021) al referirse que los modelos neuronales implementados no deben ser generalizados, es decir cada modelo de RNA debe ser diseñado considerando las características de la población de estudio.

Las redes neuronales artificiales son parte de múltiples herramientas de la inteligencia artificial, que en los últimos años han desempeñado un papel de suma importancia en los múltiples procesos educativos. En este contexto, Menacho (2017) implementa un modelo predictivo con la finalidad de anticiparse al rendimiento académico de estudiantes universitarios, similarmente Martins et al. (2020) implementaron un modelo para anticiparse a la deserción estudiantil, al igual que Lejía et al. (2010), quienes anticiparon los resultados académicos en un centro pre universitario. En general, los avances tecnológicos deben ser involucrados en el sector educación para resolver problemas que este presenta. Además, conocer tempranamente los posibles resultados académicos al final de un determinado periodo en los estudiantes como se observa en la Tabla 4, le otorga al docente la posibilidad de tomar a tiempo las medidas correctivas y de mejora, a fin de revertir estos resultados en el supuesto caso que no sean los mejores, o en su virtud reforzar con éxito el logro de las competencias adquiridas.

Esta investigación aporta conocimiento teórico y práctico en el ámbito educativo: en lo teórico, propicia la investigación multidisciplinaria, involucrando el conocimiento existente de la IA para realizar investigaciones que den solución a problemas que presenta este sector (Moreira et al., 2019); en lo práctico, otorga al docente y a la institución educativa los posibles resultados académicos de la comunidad estudiantil prematuramente, con el objetivo de que los involucrados en el logro de competencias, puedan implementar acciones correctivas y/o de mejora en el proceso de enseñanza y aprendizaje, logrando mejores resultados en el logro de competencias en los estudiantes (López-Aguilar & Álvarez-Pérez, 2021).

Algunas limitaciones relevantes en el desarrollo de esta investigación, son el acceso a internet de los estudiantes y la deserción estudiantil como consecuencias de la pandemia Covid-19. Visto las implicaciones teóricas y prácticas en beneficio de la educación, recomendamos replicar investigaciones que involucren herramientas de la IA en las demás instituciones educativas, teniendo en cuenta las características de la población. Con la finalidad de fortalecer a la comunidad educativa se recomienda realizar investigaciones que involucren la deserción estudiantil, ya que en estos tiempos de pandemia se ha incrementado considerablemente.

Conclusiones

Se demuestra que es posible predecir el resultado académico de los estudiantes del segundo grado de la Institución Educativa N°16093 en la provincia de Jaén-Perú, el modelo de red neuronal artificial implementado logró una efectividad del 88.670% en la predicción exacta del promedio redondeado al entero más cercano. Sin embargo, la efectividad aumenta al 98.522% si se considera una diferencia ± 1 del promedio.

Las redes neuronales artificiales demuestran ser una herramienta importante en el sector educativo con fines predictivos para lograr una mejora en el logro de resultados; no obstante, los modelos neuronales no deben ser duplicados puesto que cada unidad de estudio tiene sus propias características dentro de un contexto sociocultural en un determinado espacio-tiempo.

Referencias

- Álvarez, J., Lau, R., Pérez, S., & Leyva, E. C. (2016). Predicción de resultados académicos de estudiantes de informática mediante el uso de redes neuronales. *Ingeniare. Revista chilena de ingeniería*, 24 (4), 715-727. <https://doi.org/10.4067/S0718-33052016000400015>
- Barreto, W. & Picón, R. (2020). Experimental and simulation study of composite panels inelastic behavior using Artificial Neural Networks. *Informes de la Construcción*, 72(558), 1-10. <https://doi.org/10.3989/ic.70957>
- Çetinkaya, A. & Baykan, Ö. K. (2020). Prediction of middle school students' programming talent using artificial neural networks. *Engineering Science and Technology, an International Journal*. <https://doi.org/10.1016/j.jestch.2020.07.005>
- Comella, A., Casas-Baroy, J.-C., Comella-Company, A., Galbany-Estragués, P., Pujol, R. & Marc-Amengual, J.-M. (2021). Burnout and academic performance: Effect of the combination of remunerated jobs and starting university degree studies. *Retos*, 41, 844-853. <https://doi.org/10.47197/RETOS.V41I0.85971>
- Costa, E. B., Fonseca, B., Santana, M. A., de Araújo, F. F., & Rego, J. (2017). Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses. *Computers in Human Behavior*, 73, 247-256. <https://doi.org/10.1016/j.chb.2017.01.047>
- Criollo, M., Romero, M., & Fontaines-Ruiz, T. (2017). Autoeficacia para el aprendizaje de la investigación en estudiantes universitarios. *Psicología Educativa*, 23 (1), 63-72. <https://doi.org/10.1016/j.pse.2016.09.002>

- da Silva, A. X., de Oliveira, S. C., & de Araújo, R. F. G. (2020). Propuesta de prototipo de aplicación de Android para diagnósticos de enfermería utilizando redes neuronales artificiales. *Revista Cubana de Enfermería*, 36 (2), Article 2. <http://revenfermeria.sld.cu/index.php/enf/article/view/3252>
- Díaz-Muñoz, G. (2020). Metodología del estudio piloto. *Revista chilena de radiología*, 26 (3), 100-104. <https://doi.org/10.4067/S0717-93082020000300100>
- Echeverría-Ramírez, J. A., & Mazzitelli, C. (2021). A study of the perception of the institutional factors that influence the academic performance of students of the Distance State University of Costa Rica. *Revista Electrónica Educare*, 25 (2). <https://doi.org/10.15359/ree.25-2.18>
- Ferraces, M. J., Moledo, M. L., Otero, A. G. & Santos, M. A. (2021). Students' mediator variables in the relationship between family involvement and academic performance: Effects of the styles of involvement. *Psicologia Educativa*, 27 (1), 85-92. <https://doi.org/10.5093/PSED2020A19>
- Figueroa-Garcia, E., Farias-Cervantes, V. S., Segura-Castruita, M., Andrade-Gonzalez, I., Montero-Cortés, M. I., & Chávez-Rodríguez, A. M. (2021). Using artificial neural networks in prediction of the drying process of foods that are rich in sugars. *Revista Mexicana de Ingeniera Quimica*, 20 (1), 161-171. <https://doi.org/10.24275/rmiq/Sim1403>
- Foster, R. C. (2020). A generalized framework for classical test theory. *Journal of Mathematical Psychology*, 96. <https://doi.org/10.1016/j.jmp.2020.102330>
- Foster, R. C. (2021). KR20 and KR21 for Some Nondichotomous Data (It's Not Just Cronbach's Alpha). *Educational and Psychological Measurement*. <https://doi.org/10.1177/0013164421992535>
- González-García, N., Sánchez-García, A. B., Nieto-Librero, A. B., & Galindo-Villardón, M. P. (2019). Actitud y enfoques de aprendizaje en el estudio de la Didáctica General. Una visión multivariante. *Revista de Psicodidáctica*, 24 (2), 154-162. <https://doi.org/10.1016/j.psicod.2019.02.002>
- González-Velasco, C., Feito-Ruiz, I., González-Fernández, M., Álvarez-Arenal, J.-L. & Sarmiento-Alonso, N. (2021). Does the teaching-learning model based on the flipped classroom improve academic results of students at different educational levels? *Revista Complutense de Educacion*, 32 (1), 27-39. <https://doi.org/10.5209/RCED.67851>

- Goyes-Peñafiel, P. & Hernandez-Rojas, A. (2021). Double landslide susceptibility assessment based on artificial neural networks and weights of evidence. *Boletín de Geología*, 43 (1), 173-191. <https://doi.org/10.18273/revbol.v43n1-2021009>
- Hernández, R. M. (2018). La estrategia didáctica frente a los estilos de aprendizaje en la educación superior. *Educación Médica*, 19, 227. <https://doi.org/10.1016/j.edumed.2017.10.034>
- Incio, F. A. & Capuñay, D. L. (2020). Liderazgo directivo y desempeño docente en instituciones educativas particulares. *Revista Científica Epistemia*, 4 (3), 119-128. <https://doi.org/10.26495/re.v4i3.1422>
- Incio, F. A., Capuñay, D. L., Estela, R. O., Delgado, J. A. & Vergara, S. E. (2021). Diseño e implementación de una red neuronal artificial para predecir el rendimiento académico en estudiantes de Ingeniería Civil de la UNIFSLB. *Revista Veritas et Scientia*, 10 (1), 107-117. <https://doi.org/10.47796/ves.v10i1.464>
- International Business Machines Corporation. (2021). *Conceptos básicos de ayuda de CRISP-DM*. Conceptos básicos de ayuda de CRISP-DM. <https://prod.ibmdocs-production-dal-6099123ce774e592a519d7c33db8265e-0000.us-south.containers.appdomain.cloud/docs/es/spss-modeler/SaaS?topic=dm-crisp-help-overview>
- Johnson, K. B., Ferguson, D. H., Tempke, R. S. & Nix, A. C. (2021). Application of a Convolutional Neural Network for Wave Mode Identification in a Rotating Detonation Combustor Using High-Speed Imaging. *Journal of Thermal Science and Engineering Applications*, 13 (6). <https://doi.org/10.1115/1.4049868>
- Lejía, C.-T., Ng, L.-N., Hassan, M. D., Goh, W.-W., Ley, C.-Y. & Ismail, N. (2010). *Predicting pre-university students' mathematics achievement*. 8, 299-306. <https://doi.org/10.1016/j.sbspro.2010.12.041>
- López-Aguilar, D. & Álvarez-Pérez, P. R. (2021). Modelo predictivo PLS-SEM sobre intención de abandono académico universitario durante la COVID-19. *Revista Complutense de Educación*, 32 (3), 451-461. <https://doi.org/10.5209/rced.70507>
- Martins, M. P. G., Migueis, V. L., Fonseca, D. S. B. & Gouveia, P. D. F. (2020). Prediction of academic dropout in a higher education institution using data mining. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, 2020 (E28), 188-203.
- Menacho, C. H. (2017). Predicción del rendimiento académico aplicando técnicas de minería de datos. *Anales Científicos*, 78 (1), 26-33. <https://doi.org/10.21704/ac.v78i1.811>

- Moreira, F., Ferreira, M. J., Pereira, C. S., Gomes, A. S., Collazos, C. & Escudero, D. F. (2019). ECLECTIC as a learning ecosystem for higher education disruption. *Universal Access in the Information Society*, 18 (3), 615-631. <https://doi.org/10.1007/s10209-019-00682-x>
- Olascoaga, A. C. (2020). Curso de docencia para residentes: Evaluación de un programa. *Educación Médica*, 21 (3), 187-192. <https://doi.org/10.1016/j.edumed.2018.07.010>
- Pal, J. & Chakrabarty, D. (2020). Assessment of artificial neural network models based on the simulation of groundwater contaminant transport. *Hydrogeology Journal*, 28 (6), 2039-2055. <https://doi.org/10.1007/s10040-020-02180-4>
- Pizarro, S., Santillán, G., Vilela, J. & Hildebrandt, A. (2021). Factors related to academic performance in Veterinary Medicine students. *Revista de Investigaciones Veterinarias del Peru*, 32 (1). <https://doi.org/10.15381/RIVEP.V32I1.19509>
- Porras, M. M. & Ortega, F. H. (2021). Procrastination, test anxiety and academic performance on university students. *Interdisciplinaria*, 38 (2), 243-258. <https://doi.org/10.16888/INTERD.2021.38.2.16>
- Ramos, R. T. & Gómez, N. N. (2021). The influence of the teacher on the motivation, learning strategies, critical thinking and academic performance of high school students in Physical Education. *Psychology, Society and Education*, 11 (1), 137-150. <https://doi.org/10.25115/psye.v11i1.2230>
- Rodríguez, D. D., Ordoñez, R. E. & Hidalgo-Villota, M. E. (2021). Determinantes del rendimiento académico de la educación media en el departamento de Nariño, Colombia. *Lecturas de Economía*, 94, 87-126. <https://doi.org/10.17533/udea.le.n94a341834>
- Rodríguez, H. E. D., Castro, M. M. S. & Rosales, M. A. C. (2021). Financial performance and administrative practices in Mexican microenterprises: An analysis with artificial neural networks. *Contaduría y Administración*, 64 (3). <https://doi.org/10.22201/FCA.24488410E.2018.1622>
- Sabir, Z., Nisar, K., Raja, M. A. Z., Ibrahim, A. A. B. A., Rodrigues, J. J. P. C., Al-Basyouni, K. S., Mahmoud, S. R. & Rawat, D. B. (2021). Design of Morlet wavelet neural network for solving the higher order singular nonlinear differential equations. *Alexandria Engineering Journal*, 60 (6), 5935-5947. <https://doi.org/10.1016/j.aej.2021.04.001>
- Sagredo, A. V., Etchepare, G. C., Mendizabal, E. A. & Wilson, C. P. (2021). Academic performance and its relationship with socioemotional variables in chilean students from vulnerable contexts. *Educacion XX1*, 24 (2), 375-398. <https://doi.org/10.5944/educxx1.28269>

- Şenyurt, M., Ercanlı, İ., Günlü, A., Bolat, F. & Bulut, S. (2020). Artificial neural network models for predicting relationships between diameter at breast height and stump diameter: Crimean pine stands at ÇAKÜ forest. *Bosque*, 41 (1), 25-34. <https://doi.org/10.4067/S0717-92002020000100025>
- Sosa, M., Ortiz, E. & Cabello, A. (2021). Impact of social lags on the number of deaths and confirmed cases by COVID-19 in Mexico: Artificial neural network analysis employing municipal information. *Contaduria y Administracion*, 65 (5). <https://doi.org/10.22201/fca.24488410e.2020.3020>
- Wingerter, D. G., de Oliveira Santos, E. G. & Barbosa, I. R. (2020). The use of artificial neural networks to classify the social vulnerability of municipalities in Rio Grande do Norte State, Brazil. *Cadernos de Saude Publica*, 36 (8). <https://doi.org/10.1590/0102-311X00038319>
- Wunderlich, T. C. & Pehle, C. (2021). Event-based backpropagation can compute exact gradients for spiking neural networks. *Scientific Reports*, 11 (1). <https://doi.org/10.1038/s41598-021-91786-z>