

Redes neuronales artificiales (RNA) para la predicción y análisis del patrón de comportamiento de aspirantes a la educación superior para la selección de institución universitaria, en la región de las montañas de Veracruz

Rita Flores-Asis, Mónica Karina González-Rosas,
Marisol Rodríguez-Gasga

Universidad Veracruzana Campus Ixtaczoquitlán,
Facultad de Negocios y Tecnologías,
México

ritflores@uv.mx

Resumen. El presente trabajo expone el análisis de las variables que intervienen en la decisión de los aspirantes a cursar una carrera universitaria, con el objetivo de predecir el patrón de comportamiento y analizar el impacto de sus decisiones. Para llevar a cabo las predicciones se diseñó un instrumento de recolección de datos (encuesta) que fue aplicada a una muestra representativa de alumnos de los últimos semestres de la Educación Media Superior, con el fin de obtener una base de datos robusta, que fue utilizada para el entrenamiento de una RNA de alimentación hacia delante con entrenamiento de retro propagación programada en Neural Network de Matlab, con el algoritmo Levenberg-Marquardt, utilizando la función de entrenamiento TRAINLM. Las variables se categorizaron en tres segmentos, variables demográficas, variables de oferta educativa y variables de marketing y difusión. Se llevó a cabo el entrenamiento con un porcentaje de predicción superior el 87%, teniendo como resultado que las variables de mayor impacto en la selección del programa educativo, y la institución para estudiar la Universidad, fueron la *oferta educativa* de las universidades, con un 22.93% de impacto en el resultado, esto demuestra que los alumnos, si se interesan en elegir la profesión para la cual consideran tener vocación, también se aprecia que las variables *procedencia* y *distancia*, con un porcentaje 12.91% y 16.31 % respectivamente, también fueron relevantes en la decisión de los aspirantes.

Palabras clave: Redes neuronales artificiales, educación, captación, predicción.

Artificial Neural Networks (ANN) for the Prediction and Analysis of the Behavioral Pattern of Prospective Higher Education Applicants for University Institution Selection, in the Mountain Region of Veracruz

Abstract. This research presents an analysis of the variables involved in the decision-making process of prospective university students, aiming to predict

behavior patterns and analyze the impact of their decisions. To make predictions, a data collection instrument (survey) was designed and applied to a representative sample of students in the final semesters of High School Education. The purpose was to obtain a robust database used for training a feedforward neural network with backpropagation training programmed in Matlab's Neural Network Toolbox, using the Levenberg-Marquardt algorithm and the TRAINLM training function. The variables were categorized into three segments: demographic variables, educational offer variables, and marketing and outreach variables. The training achieved a prediction percentage above 87%, revealing that the most impactful variables in selecting an educational program and institution for university study were the universities' educational offerings, with a 22.93% impact on the outcome. This demonstrates that students are interested in choosing a profession they feel passionate about. Additionally, it was observed that variables such as background and distance, with percentages of 12.91% and 16.31% respectively, were also relevant factors in the decision-making process of the applicants.

Keywords: Artificial neural network, education, recruitment, prediction.

1. Introducción

En México existe un total de 5,003,087 estudiantes de Educación Media Superior (EMS) también conocida como preparatoria o bachillerato [1], es el nivel educativo que se cursa antes del ingreso a la educación superior, en algunos casos, es el último nivel que cursan los alumnos antes de incorporarse al ámbito laboral. Actualmente existen tres modelos educativos: el bachillerato general, el bachillerato tecnológico y el profesional técnico con bachillerato; y cuatro tipos de sostenimiento: federal, estatal, autónomo y privado, sumado a esto, existen 5 tipos de control administrativo y presupuestal que en total forman 35 subsistemas. En el Estado de Veracruz se matricularon 300 102 alumnos durante el ciclo escolar 2021-2023 [2]. A nivel estatal, se ha observado una importante disminución del porcentaje de alumnos egresados de nivel medio superior y superior, ya que en el ciclo escolar 2000-2001 se tuvo un porcentaje del 89.5% de ingresos en nivel medio superior de los cuales egresaron un total de 84% en nivel superior, en comparación con el ciclo 2020-2021, en el que se tiene un porcentaje de ingreso a nivel medio superior del 61.1%, teniendo un egreso en nivel superior de solo 47.7%, lo que indica que la proporción de alumnos que inician el estudio del nivel medio superior y terminan sus estudios de Licenciatura va disminuyendo considerablemente [3]. Es cierto que las razones pueden ser diversas, probablemente los alumnos no eligieron la carrera o universidad adecuada a sus posibilidades económicas, o la carrera elegida no fue la que logró cumplir con sus expectativas, quizá consideran que la universidad no cuenta con los servicios necesarios para la culminación de los estudios, y en muchos casos, puede ser que los alumnos no se encontraron informados adecuadamente de las posibilidades que tuvieron en ese momento, de la gama de universidades que ofrecieron sus servicios, y desconocían varios aspectos relevantes para la selección adecuada de una casa de estudios de nivel superior que cumpliera con sus expectativas.

Sin embargo, existen otras causas que no dependen precisamente de los alumnos, también muchos de estos aspectos se derivan de las universidades, algunas de ellas no lograron cumplir con las expectativas, planes y necesidades que buscaban los egresados del nivel medio superior.

La región de las Altas Montañas en Veracruz se conforma por diversos municipios que se encuentran ubicados en la zona centro del Estado, las principales ciudades en esta región la conforman Córdoba, Orizaba, Ixtaczoquitlán, Fortín y Huatusco. La región cuenta con 50 170 estudiantes de EMS [4] debido a la disponibilidad y las características de la muestra, se selecciona el estrato de estudiantes de la zona de Huatusco para estudiar a su población próxima a egresar de la EMS, para ello, se entrenó una red neuronal artificial (RNA) de alimentación hacia delante con entrenamiento de retropropagación programada en Neural Network de Matlab.

El diseño de la RNA es de tipo perceptrón multicapa, y se caracteriza porque las neuronas están organizadas en capas y sus conexiones entre ellas se orientan estrictamente hacia una sola dirección de una capa a otra. Las RNA'S han demostrado una mejor efectividad frente a otros métodos estadísticos de regresión sin necesidad de cumplir condiciones de linealidad, normalidad o tamaño muestral, [5].

Existen algunos autores que han llevado a cabo la implementación de redes neuronales artificiales para predecir el patrón de comportamiento de estudiantes en otros enfoques de propósito educativo, tal es el caso del estudio realizado en la Facultad de Ingeniería y Tecnología de la Información en Universidad Al-Azhar [6], en este trabajo se desarrolla una RNA para predecir el rendimiento escolar de los estudiantes, se observa que los resultados esperados del entrenamiento, se obtiene un porcentaje de predicción superior al 80% de los casos considerados. Este estudio mostró el potencial de la red neuronal artificial para predecir el desempeño de los estudiantes.

Por otro lado, en el trabajo realizado por [7] en esta investigación se entrenó una RNA para predecir el rendimiento académico estudiantil, los resultados demostraron que se clasificó adecuadamente el 73% de la muestra de prueba, lo que permite concluir que la RNA es correcta para identificar los estudiantes en estatus de reprobación, también menciona que se logró identificar las variables relevantes, el tiempo de estudio, las ausencias y el tiempo de uso de redes sociales fueron los factores más importantes para determinar la probabilidad de que un estudiante apruebe o no un curso.

Las RNA's, también han sido de utilidad como una herramienta de apoyo para evaluar el proceso de aprendizaje de educación virtual [8] este estudio se evaluaron acciones y estrategias de seguimiento y retención de alumnos, el modelo predijo el rendimiento de los estudiantes con tasa de clasificación del 98,3%.

2. Metodología

2.1. Caracterización de la población meta

Para realizar el análisis de patrón de comportamiento de los alumnos que se encuentran por egresar de la EMS, se realizó una recolección de datos socioeconómicos y demográficos en un conjunto de ciudades que conforman la región montañosa del Estado de Veracruz, para ello, se llevó a cabo una recolección de datos de una muestra por estratos de alumnos aspirantes, las poblaciones de Córdoba, Orizaba, Fortín y

Tabla 1. Tabla de categorización de las variables de entrada.

Demográficos	Criterios académicos	Marketing y difusión
Procedencia	Oferta Educativa	Difusión
Edad	Distancia	Atención al cliente
Género	Becas	
Estado civil	Prestigio	
Ocupación	Modalidad	

Huatusco de la región de las Altas Montañas en Veracruz, México, son las ciudades que concentran un mayor número de estudiantes en la zona.

Para llevar a cabo instrumento de recolección se realizaron entrevistas con expertos psicólogos y pedagogos por medio del método Delphi, para redactar y determinar los planteamientos adecuados que debían ser incluidos en la encuesta que fue aplicada a la población muestreada, con la finalidad de identificar las principales variables que influyen en la selección de la universidad en la que pretenden continuar con sus estudios universitarios.

Después de diseñar el instrumento de recolección, se llevó a cabo una investigación de campo, se visitaron diferentes instituciones educativas del nivel medio superior, para aplicarla a una muestra representativa de 6200 alumnos, que se encontraban cursando el quinto semestre, entre las instituciones que colaboraron, se pueden mencionar, alumnos de telebachillerato de Veracruz (TEBAEV), alumnos de bachillerato general y alumnos del Colegio de Bachilleres de Veracruz (COBAEV), cabe mencionar que los datos obtenidos han sido protegidos y han quedado a reserva de la institución, bajo su política de privacidad.

2.2. Entrenamiento de redes neuronales artificiales

Con el deseo de explorar y analizar el comportamiento de los datos sociodemográficos obtenidos por medio de las encuestas aplicadas, se optó por realizar el desarrollo de una red neuronal artificial (RNA) para realizar predicciones sobre los factores que influyen en la decisión de los alumnos de EMS en el momento de seleccionar su carrera profesional y la institución en la que continuarán con sus estudios, se consideraron 12 variables de entrada, que fueron obtenidas de un instrumento de recolección cualitativa, se estimaron parámetros numéricos para interpretar las expresiones lingüísticas resultantes de las encuestas, mismas que fueron categorizadas en 3 segmentos, en la tabla 1, se expone las variables de entrada que son categorizadas en variables demográficas, criterios académicos y variables de marketing y difusión de las universidades.

En la tabla 2, se presentan los parámetros que forman parte de las variables de entrada y salida de la red neuronal artificial, en la que se estima la predicción de la institución universitaria y la carrera profesional de preferencia de la población muestra.

Tabla 2. Definición de parámetros de las variables de entrada de las RNA'S.

Variable	Nombre	Definición	Unidad de medida
x1	Procedencia	Lugar de procedencia	Km
x2	Edad	Edad del aspirante	Numérica/años
x3	Género	Sexo del aspirante	Numérica
x4	Estado civil	Estado civil del aspirante	Numérica
x5	Ocupación	Ocupación del aspirante	Numérica
x6	Oferta educativa	Carreras profesionales ofertadas	Numérica
x7	Distancia	Ubicación del plantel Universitario	Km
x8	Becas	Plan de becas ofertadas por la institución	Numérica
x9	Prestigio	Calificación ponderada sobre la percepción del prestigio institucional	Numérica
x10	Modalidad	Opciones de acceso a la educación presencial, semipresencial o virtual.	Numérica
x11	Difusión	Percepción de la información que difunde cada universidad.	Numérica
x12	Atención al cliente	Percepción de la atención que ofrece cada universidad.	Numérica
y1	Universidad seleccionada	Selección de universidad de la lista de opciones	Numérica
y2	Programa seleccionado	Carrera profesional seleccionada	Numérica

“Una RNA es una técnica de Inteligencia Artificial (I.A.) que funciona a través de un modelo matemático que predice el patrón de comportamiento de sistemas lineales y no lineales” [9]. Las redes neuronales se agrupan en dos categorías en función del patrón de conexiones que presentan, las redes de alimentación hacia delante y las de retroalimentación o recurrentes.

Las redes de alimentación hacia adelante son aquellas donde no existen ciclos o retroalimentaciones, sus conexiones son unidireccionales y solo permiten señales hacia un solo sentido entre las neuronas de cada capa, y pueden ser de tipo Monocapa (de perceptrón simple), Multicapa (de perceptrón multicapa) y de función de base radial.

Los pasos para programar una red neuronal son: diseño de la arquitectura, entrenamiento, validación y prueba [10]. El diseño de una neurona artificial se representa en la Figura 1.

La expresión matemática utilizada en la neurona artificial se expresa en la Ecuación. (1). Los valores de (x_i) son los valores de entrada, (w_{ji}) son los coeficientes de los pesos de la neurona j , (b) es bias, que es considerado un valor de sesgo que permite ajustar los pesos de la neurona para lograr un error mínimo de salida, (y) son los valores de salida, y (f) es la función de transferencia sigmoide.

Los pesos de los datos de entrada son seleccionados de manera aleatoria, en un rango normalizado entre $[-1,1]$, para lograrlo se utiliza la función de MAPMINMAX de Matlab para normalizar el valor mínimo y máximo de cada elemento de entrada y salida, ecuación (1):

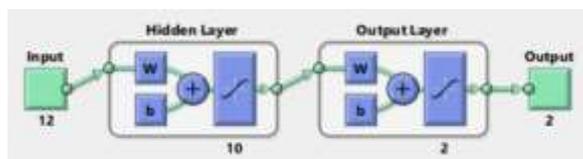


Fig. 2. Diagrama de configuración de la RNA de predicción de la selección Universitaria.

$$y_j = f[\sum_{i=0}^n w_{ji}x_i + b]. \quad (1)$$

La expresión matemática de la función Sigmoide se indica en la ecuación (2):

$$f(z) = \frac{1}{1+e^{-z}}. \quad (2)$$

El método de entrenamiento Levenberg-Marquardt generalmente es el más rápido, seguido del método BFGS Quasi-Newton, se recomiendan utilizarlos para redes que tienen un número pequeño o mínimo de salidas [11] por su mejor ajuste en problemas no lineales para minimizar la suma del error cuadrático medio.

Considerando esta recomendación este trabajo de investigación utiliza una RNA de alimentación hacia adelante con entrenamiento de retropropagación programada en Neural Network de Matlab.

Se configuró la RNA con el algoritmo Levenberg-Marquardt, utilizando la función de entrenamiento TRAINLM. Se considera la función de aprendizaje de adaptación LEARNGDM, la función de desempeño MSE que expresa el error cuadrático medio y se definen dos capas ocultas, en la primera utiliza 10 neuronas y un bias, en la segunda capa solo una neurona y un bias. Ver figura 2.

El entrenamiento de la red tiene un error cuadrático medio (MSE) de 0.001 y la raíz del error cuadrático medio (RMSE) es de 0.0316. La validación se realiza con 5600 muestras cuyo resultado fue un MSE de 0.01 y un RMSE de 0.1, el coeficiente de determinación (R2) de predicción de la validación es de 0.89975, la Fig. 3 muestra su comportamiento.

La prueba se realiza con 3500 muestras nuevas para la predicción, logrando un MSE de 0.01 y un RMSE de 0.1, el coeficiente de determinación (R) de predicción de la prueba es 0.87514, teniendo un porcentaje aceptado para las pruebas de validación en una RNA, [12] ver Fig. 4. Los outliers que se observan en las figuras 4 y 5 representan algunos valores atípicos dado que la población no cumple con algunos de los criterios que se podían seleccionar en el instrumento de recolección, debido a que el instrumento de recolección se desarrolló con el objetivo de ser aplicado a diferentes estratos de la población meta, en el apartado de caracterización de la muestra se hace mención que para fines del análisis del presente trabajo, solo ha sido evaluado un estrato de la población objetivo.

3. Resultados y discusión

3.1. Predicción de la RNA

Después de realizar el entrenamiento y la validación del entrenamiento de la RNA, es necesario llevar a cabo la predicción de forma automática en los 5600 y 3500 casos que se consideraron para el entrenamiento de la red, en la tabla 3 se observa un

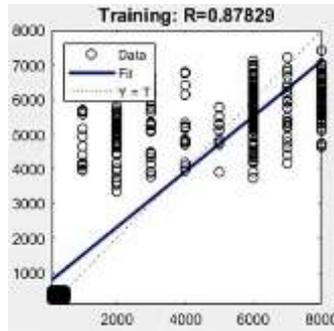


Fig. 3. Coeficiente de determinación (R) de la validación en la predicción durante la etapa de entrenamiento de la RNA en 6500 muestras.

fragmento de los casos predichos. La red fue entrenada en repetidas ocasiones, logrando un porcentaje de predicción superior al 89%, coincidiendo con los resultados obtenidos por [13] el cual menciona que entrenó una RNA con un porcentaje de predicción superior al 84%.

En la tabla 3, se presentaron los resultados obtenidos por la RNA, y en la tabla 4, se muestra la interpretación de parámetros cuantitativos migrados a parámetros cualitativos, en la cual se describe y especifica los valores numéricos que representan las diferentes etiquetas (alternativas) con respecto a las preferencias de los aspirantes a la Educación Superior, en relación con la Institución Universitaria a la que se pretenden postular y el área de conocimiento de su perfil profesional, teniendo como parámetros de entrada las variables $x_1 \dots x_{12}$, los parámetros que se consideran en cada una de estas variables de entrada-salida se encuentran detallados en la tabla 2.

En la tabla 3 se observan 10 muestras de los resultados obtenidos en las predicciones. En la muestra 1, el parámetro 1 hace referencia a la variable de entrada x_1 que corresponde al lugar de procedencia, dicho parámetro se encuentra estimado en Kilómetros, lo que indica que el lugar de procedencia es alrededor de 1 km de alguna de las alternativas de universidad a la que aspira ingresar el estudiante, x_2 representa la edad del estudiante, en este caso 17 años, x_3 se refiere al género, los valores utilizados para convertir de dato cualitativo a dato cuantitativo para facilitar su análisis por medio de una RNA, corresponden a 100 = mujer, 200 = hombre y 300 = no binario, la variable x_4 es el estado civil del encuestado, donde el valor 1 corresponde a la opción soltero y el valor 2 significa estar casado, la variable x_5 se refiere a si el aspirante solo se dedica a estudiar (1000) si solo trabaja por el momento (2000) o trabaja y estudia (3000), en este caso se presenta un sesgo, ya que todos los aspirantes encuestados se dedican a estudiar, o bien trabajan y estudian, ya que la muestra seleccionada corresponde a estudiantes de EMS, la intención de mantener la opción de solo trabajar, se debe, a que se pretende ampliar la muestra de estudio a otros segmentos.

La variable de entrada x_6 se refiere a la oferta educativa de interés, se cuentan con 8 opciones de oferta educativa, para la muestra 1, 4 representa el área de diseño digital, para el caso de la variable x_7 , se relaciona con la distancia de la ubicación del plantel, que se encuentra dada en Kilómetros, la variable x_8 expresa las opciones de beca que ofrece el plantel, x_9 mide el prestigio del plantel, cuya medida se puntúa en escala de 100 a 800, x_{10} representa la modalidad de estudio, donde 1 es presencial, 2 es virtual

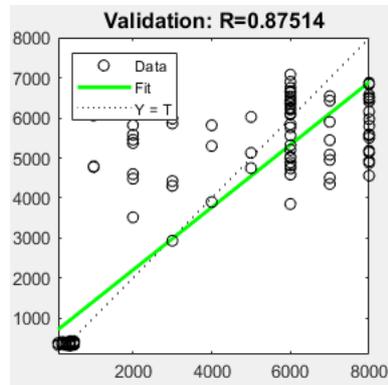


Fig. 4. Coeficiente de determinación (R) de la validación de la predicción durante la etapa de entrenamiento de la RNA en 3500 muestras.

y 3 es sistema abierto, para el caso de la variable x_{11} , estima la percepción de la difusión de Universidad, la variable se puntúa de 1000 a 10000, con intervalos del 1000 en 1000, la última variable x_{12} , muestra el parámetro de la percepción de calidad en atención al cliente, la medición se expresa de 100 a 100 con intervalos de 100 en 100.

Por último, las variables de respuesta (salida) se representan con y_1 y y_2 , en la tabla 4 se precisa de manera detallada su equivalencia del parámetro numérico resultante a su etiqueta lingüística (cualitativa). Con estos resultados, podemos mencionar que las RNA'S permiten entrenar valores numéricos, obteniendo parámetros cuantitativos altamente confiables, que pueden ser interpretados para medir y exhibir aspectos cualitativos de la población analizada [14], con el fin de estimar su patrón de comportamiento.

Las redes neuronales artificiales tienen la capacidad de exponer un panorama de las variables relevantes en las predicciones por medio del entrenamiento de datos. Utilizando el software Neural Tools 5.5, de PALISADE, se llevó a cabo un segundo análisis de los datos, por medio de una red neuronal de regresión generalizada utilizada para la predicción y clasificación categórica (PNN/GRNN), con la finalidad de evaluar el impacto, una de las características que ofrece como resultado dicho software, es la posibilidad de ofrecer un porcentaje de impacto en las variables de pérdida.

El gráfico de tornado que se muestra en la figura 5, demuestra el porcentaje de impacto de cada variable de entrada, con respecto a la variable de salida, se puede apreciar que la variable que representa el mayor porcentaje de impacto en la selección del programa educativo, y la institución para estudiar la Universidad es la oferta educativa, con un 22.93% , esto demuestra que los alumnos, si se interesan en elegir la profesión para la cual consideran tener vocación, también se aprecia que las variables procedencia y distancia, con un porcentaje 12.91% y 16.31 % respectivamente, lo cual hace referencia a los kilómetros de distancia de su lugar de vivienda y la distancia a la universidad predilecta , son dos variables que son detonantes al momento de decidir su futuro, con esto verificamos que las RNA'S son una herramienta viable para obtener resultados confiables en niveles de presión e interpretación de una gran cantidad de datos [15].

Tabla 3. Fragmento de resultados de la predicción de la RNA.

Muestras	Variables de entrada												Variables de Salida	
	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	y1	y2
1	1	100	17	1	1000	4	10	10	800	1	5000	200	4000	5
2	6	100	18	1	2000	7	16	5	100	1	1000	100	4000	2
3	4	200	17	1	1000	2	22	8	150	1	4000	300	1000	2
4	7	100	16	1	1000	1	55	9	200	2	1000	500	5000	1
5	2	200	18	1	1000	2	16	4	800	1	1000	100	4000	3
6	7	200	17	1	3000	8	22	6	700	3	2000	300	5000	2
7	2	200	17	2	1000	2	2	8	800	1	6000	900	2000	2
8	4	100	17	1	2000	6	135	5	100	1	7000	100	3000	1
9	8	200	18	1	1000	1	296	2	300	2	1000	300	4000	5
10	1	100	19	1	1000	4	55	8	100	1	2000	600	7000	3

Tabla 4. Interpretación de los parámetros numéricos resultantes en la elección de la población muestra.

y1	Universidad	y2	Programa educativo categorizado
1000	Tecnológico de Huatusco	1	Prof. Humanidades
2000	UTCV	2	Prof. econó-administrativo
3000	BUAP	3	Prof. área médica
4000	UV	4	Prof. en Artes
5000	Tecnológico de Orizaba	5	Prof. en Ingeniería
6000	UNAM		
7000	Virtual		
8000	Privada		

4. Conclusiones

El conocer las necesidades y expectativas de los estudiantes, permitirá identificar la demanda educativa de educación Superior de la región y las carreras profesionales de mayor solicitud por parte de los alumnos, así como identificar la cantidad de estudiantes que prefieren emigrar de la región para buscar otra oferta educativa o incluso otras oportunidades de empleo, también permite saber cuántos alumnos tienen altas intenciones de acceder a los principales programas de apoyo social, ya sea para solicitar una beca o ser parte de uno de los programas de capacitación laboral.

Podemos deducir que las redes neuronales artificiales son una herramienta de minería de datos muy útil para la predicción de datos cuantitativos y cualitativos, que proporcionaron escenarios de las expectativas y decisiones de los aspirantes a la educación Superior, además de mostrar un análisis cuantitativo para estimar

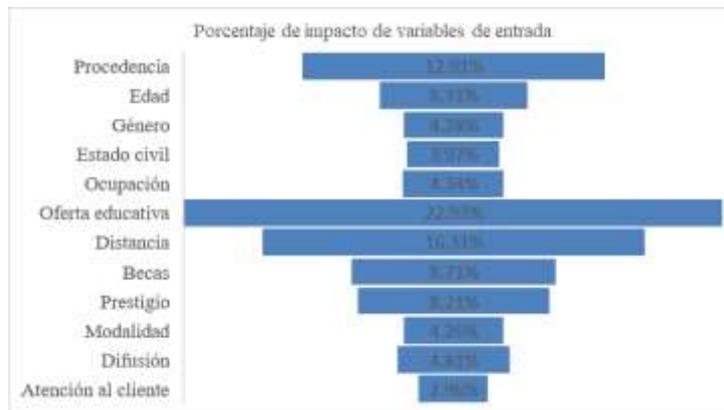


Fig. 5. Gráfica de porcentaje de impacto de las variables de entrada con las variables de salida.

indicadores de migración, la movilidad en las comunidades de la región, la empleabilidad, y el impacto económico. Los resultados expuestos en el presente trabajo de investigación pueden ser utilizados como base o fundamento, para detonar estrategias de captación de alumnos, por parte de las instituciones educativas con el fin de fomentar y gestionar el desarrollo social y educativo de la región de las montañas de Veracruz.

Referencias

1. Toscano, L.R.: Análisis de la educación en México: Barreras y limitantes para la congruencia, la calidad y la cobertura educativa actual. *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, pp. 4851–4883 (2023). DOI: 10.37811/cl_rcm.v7i1.4805.
2. Huerta-Estévez, A., Severino-Parra, C.A., León, F.V.: Agenda 2030 y educación de calidad en México, avances en el cumplimiento para el 2030. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, vol. 14, no. 27, pp. e517 (2023). DOI: 10.23913/ride.v14i27.1567.
3. INEGI.: Informe anual de actividades y resultados 2022. Órgano Interno de Control. Instituto Nacional de Estadística y Geografía, pp. 1–140. <https://ci.inegi.org.mx/docs/InformeAnual2022OIC.pdf>. (2022)
4. INEGI.: Anuario estadístico y geográfico por entidad federativa 2017. Instituto Nacional de Estadística y Geografía, pp. 1–641. https://www.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/aegef_2017/702825097929.pdf. (2017)
5. Inicio-Flores, F.A., Capuñay-Sanchez, D.L., Estela-Urbina, R.O., Delgado-Soto, J.A., & Vergara-Medrano, S.E.: 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-UPT*, vol. 10, no. 1, pp. 107–117 (2021). DOI: 10.47796/ves.v10i1.464.
6. Naser, S.A., Zaqout, I., Ghosh, M.A., Atallah, R., & Alajrami, E.: Predicting student performance using artificial neural network: In the faculty of engineering and information technology. *International journal of hybrid information technology*, vol. 8, no. 2, pp. 221–228 (2015). DOI: 10.14257/ijhit.2015.8.2.20.

7. Gil-Vera, V.D., Quintero-López, C.: Predicción del rendimiento académico estudiantil con redes neuronales artificiales. *Información tecnológica* vol. 32, no. 6, pp. 221–228 (2021). DOI: 10.4067/s0718-07642021000600221.
8. Zacharis, N.Z. Predicting student academic performance in blended learning using artificial neural networks. *International Journal of Artificial Intelligence and Applications*, vol. 7, no. 5, pp. 17–29 (2016). DOI: 10.5121/ijaia.2016.7502.
9. Flores-Asis, R., Méndez-Contreras, J.M., Juárez-Martínez, U., Alvarado-Lassman, A., Villanueva-Vásquez, D., & Aguilar-Lasserre, A.A.: Use of artificial neuronal networks for prediction of the control parameters in the process of anaerobic digestion with thermal pretreatment. *Journal of Environmental Science and Health, Part A*, vol. 53, no. 10, pp. 883–890 (2018). DOI: 10.1080/10934529.2018.1459070.
10. Purroy-Vasquez, R., Aguilar-Lasserre, A.A., Meza-Palacios, R., & Fernández-Lambert, G. Artificial neural network (ANN) in forecasting of poverty line and economic-energetic efficiencies into the maize-based agroecosystems. *Archives of Agronomy and Soil Science*, vol. 70, no. 1, pp. 1–17 (2024). DOI: 10.1080/03650340.2023.2287751.
11. Miranda-Ackerman, M.A., Azzaro-Pantel, C., Aguilar-Lasserre, A.A.: A green supply chain network design framework for the processed food industry: Application to the orange juice agrofood cluster. *Computers & Industrial Engineering*, vol. 109, pp. 369–389 (2017). DOI: 10.1016/j.cie.2017.04.031.
12. Bellido-Anicama, A.B., Schwarz-Diaz, M.: Redes neuronales para predecir el comportamiento del conjunto de activos financieros más líquidos del mercado de valores peruano. *Revista Científica de la UCSA*, vol. 6, pp. 49–64 (2019). DOI: 10.18004/ucsa/2409-8752/2019.006(01)049-064.
13. Lau, E.T., Sun, L., Yang, Q. Modelling, prediction and classification of student academic performance using artificial neural networks. *SN Applied Sciences*, vol. 1, e982 (2019). DOI: 10.1007/s42452-019-0884-7.
14. Mohammadi, M., Khorrami, M.K., Ghasemzadeh, H., Noor, P., & Zandbaaf, S.: Artificial neural network for quantitative and qualitative determination of the viscosity of nanofluids by ATR-FTIR spectrometry. *Infrared Physics & Technology*, vol. 118, pp. 103900 (2021). DOI: 10.1016/j.infrared.2021.103900.
15. Marinó, G.C., Petrini, A., Malchiodi, D., Frasca, M.: Deep neural networks compression: A comparative survey and choice recommendations. *Neurocomputing*, vol. 520, pp. 152–170 (2023). DOI: 10.1016/j.neucom.2022.11.072.