

Sistema experto para predecir la deserción escolar con Inteligencia artificial académico

RESUMEN: La deserción escolar, es considerada como el abandono de la formación profesional por parte del estudiante; sin embargo, por diversas situaciones este objetivo se ve truncado, e.g., bajo desempeño académico, falta de apoyo económico, embarazos no deseados. Es idóneo que el estudiante que esta propenso a perder su calidad como estudiante sea identificado, canalizado y atendido por el área correspondiente, sin embargo, este análisis es complejo al implicar emociones, situaciones y comportamientos humanos, por lo que el estudio presenta un sistema experto basado en Redes Neuronales Artificiales capaz de predecir si un estudiante continuará o no con su formación profesional a nivel profesional, a partir de diversas variables de su contexto. Para la construcción del sistema se conformó una Big Data con los expedientes académicos, posteriormente se aplicó un Análisis de Componentes Principales para determinar la significancia de las variables, finalmente se determinó la configuración óptima de la Red Neuronal Artificial Multicapa que mejor ajusta los valores observados con los esperados. El estudio desarrollado arroja que las variables de impacto son: con quien vivirá durante los estudios, estado civil y carrera; con una significancia sobre la variable de interés de más del 80.00%. El sistema experto presenta una eficiencia del 90.90%.

PALABRAS CLAVE: Sistema Experto, Redes Neuronales Artificiales, Patrones de Comportamiento, Deserción Escolar.



Colaboración

Aarón Montiel Rosales; Nayeli Montalvo Romero,-
Tecnológico Nacional de México / ITS de Purísima del
Rincón

ABSTRACT: School dropout is the abandonment of vocational training by the student; however, by various situations this objective is truncated, e.g., under academic performance, lack of financial support, unwanted pregnancies. It is ideal that the student who is prone to lose his or her quality as a student is identified, channeled and attended by the corresponding area, however, this analysis is complex by involving emotions, situations and human behaviors, so the study presents an expert system based on Artificial Neural Networks capable of predicting whether or not a student will continue with their professional training at the professional level, based on various variables of their context. For the construction of the system a BigData was formed with the academic records, subsequently a Main Component Analysis was applied to determine the significance of the variables, finally the optimal configuration of the Network was determined Artificial Multilayer Neural that best adjusts the observed values with the expected values. The study developed shows that the impact variables are: with whom you will live during studies, marital status and career; with a significance on the interest variable of more than 80.00%. The expert system has an efficiency of 90.90%.

KEYWORDS: Expert System, Artificial Neural Networks, Behavior Patterns, School Dropout.

INTRODUCCIÓN

La UNESCO (United Nations Educational, Scientific and Cultural Organization), concibe a la educación como un derecho humano para todos a lo largo de la vida, siendo esta la mejor inversión para alcanzar un futuro sostenible. En septiembre del 2015, cuando se aprobó la Agenda 2030 para el Desarrollo Sostenible la comunidad internacional reconoció que la educación es fundamental para el éxito de los 17 objetivos escogidos. El programa busca erradicar la pobreza mediante el desarrollo sostenible. En el Objetivo de Desarrollo Sostenible 4, se plasma de manera esencial la ambición en el ámbito de la educación, siendo esta "Garantizar una educación inclusiva, equitativa y de calidad, y promover oportunidades de aprendizaje durante toda la vida para todos" [1].

En México, según la INEGI (Instituto Nacional de Estadística, Geografía e Informática) en su Encuesta Intercensal 2015 se tiene que el 15.00% de la población concluye el nivel primaria, el 23.70% la secundaria, el 21.70% el nivel medio superior y finalmente, el 18.60% el superior; siendo este último nivel el que impulsa el desarrollo tecnológico del país. En el ciclo escolar 2016-2017 el Tecnológico Nacional de México (TecNM) matriculó a un total de 581,835 estudiantes, de los cuales 576,614 pertenecieron a nivel licenciatura, 4,158 a maestría, 692 a doctorado, 115 a especialización y 256 TSU (Técnico Superior Universitario). A nivel nacional el TecNM en el 2018 mostró una participación en la Educación Superior con una matrícula de 13.1%, una participación en licenciatura de 14.09% y en posgrado una participación de 1.41%. La principal matrícula presente en el TecNM se efectúa a nivel licenciatura, siendo representada con el 99.10% distribuida en 43 programas de estudio. Según datos de la Dirección de Planeación y Evaluación del TecNM al 2017 se presentó una eficiencia terminal del 58% a nivel nacional. El logro de un futuro sostenible a través del Objetivo de Desarrollo Sostenible 4, bien puede ser apoyado al encausar todos los esfuerzos en formar profesionistas íntegros, tal y como lo establece la formación del TecNM.

Formar profesionistas que apoyen al desarrollo económico, social y cultural de la región, del estado y del país; es una meta en común de la sociedad, gobierno e Instituciones de Educación Superior (IES). Es por ello, el interés de los tres ejes en establecer estrategias para que la persona que decide formarse profesionalmente en una IES sea apoyada por medio de becas, infraestructura, empleos, entre otras. De manera interna las IES apoyan a los estudiantes, a través de becas, actividades extraescolares, asesorías académicas, programa de tutorías, por mencionar algunas. Siendo el programa de tutorías un eje importante en el desempeño del estudiante, para que éste culmine su formación profesional; bajo este contexto, un estudiante puede no concluir su formación debido a múltiples factores.

Las causas que influyen en el abandono escolar se pueden agrupar en los siguientes factores: personal (embarazo no deseado, falta de interés, fallecimiento de algún familiar, entre otras) [2], económico (ingreso económico familiar insuficiente, trabajar) [3], entorno familiar (falta de apoyo por los padres, desintegración familiar, entre otros) [4], académico (proceso enseñanza-aprendizaje tedioso y austero) [5]. La deserción escolar trae consigo la marginación de los desertores en lo económico, político, social y afectivo [6-8]. En [9] se presenta un enfoque que describe el comportamiento de la deserción estudiantil basado en la teoría psicológica, teoría ambiental, teoría económica, teoría organizacional y teoría interaccional. Con la intención de entender las causas de la deserción escolar, e implementar estrategias de retención se han desarrollado el Modelo de Spady en 1970, el Modelo de Fishbein y Ajzen en 1975, el Mode-

lo de Ethington en 1990, el Modelo de Tinto en 1987, el Modelo de Bean en 1985 y el Modelo de Pascarella y Terenzini en 1985 [10]. El proceso de toma de decisiones, que sigue un estudiante al evaluar la alternativa de abandonar su formación profesional, está inmerso de por lo menos uno de los factores anteriormente expuestos. El ó los factores que influyen en la decisión del estudiante están basados principalmente en emociones y sentimientos, por lo que el análisis se torna complejo.

En la literatura existen aportaciones de herramientas pertenecientes al campo de la Artificial Intelligence (AI) que sirven de apoyo para eficientizar el desempeño del proceso enseñanza-aprendizaje, e.g., en [11] se presenta un modelo híbrido de Identificación de Conceptos Erróneos (Misconception Detection and Identification, MDI), que incorpora Fuzzy String Searching y la String Interpreting Parembance para razonar los posibles conceptos erróneos de los alumnos en el aprendizaje de un segundo idioma; un Non-dominated Sorting Genetic Algorithm (NSGA-II) es presentado en [12] para mejorar el desempeño y la precisión de grupos de aprendizaje formados de manera óptima; [13], emplean la Generación Estructurada de Coalición (Coalition Structure Generation, CSG), el Aprendizaje Bayesiano y la Teoría de Roles de Belbin, para facilitar la integración de grupos de trabajo en un contexto educativo; en [14] se propone una herramienta basada en AI que compara modelos de aprendizaje, y determina el modelo que maximiza la eficiencia del aprendizaje a partir de las necesidades y preferencias individuales del educando; se desarrolló en [15] una Machine Learning to Assess Surgical Expertise (MLASE), la cual, apoya al campo de la educación quirúrgica asistida por el aprendizaje autónomo. En [16], se presenta un enfoque de como la AI, ha estructurado el panorama educativo en cuatro categorías: contenido educativo personalizado, métodos de enseñanza innovadores, evaluación mejorada de la tecnología y, comunicación entre el alumno y profesor.

El presente trabajo de investigación aborda el desarrollo de un sistema experto basado en Artificial Neural Networks (ANN's), que apoya en predecir si un estudiante tiene el riesgo de desertar de su formación académica, apoyando así, a expertos del área del comportamiento humano para implementar los controles necesarios. Así mismo, se aborda un análisis exhaustivo de las variables de impacto debido a que los modelos cambian a partir de las variables que son específicas a ciertos sectores.

MATERIAL Y MÉTODOS

En la Figura 1, se presentan las fases implicadas en el diseño, desarrollo e implementación del sistema experto. La metodología propuesta se integra por cuatro fases: la fase I conlleva definir las variables que conformaran el estudio a partir del conocimiento de expertos del comportamiento académico, y así determinar las entradas y salida de la BigData; posteriormente, la fase II comprende integrar la información de los expedientes

de estudiantes proporcionada por el Departamento de Tutorías de la IES bajo estudio a la BigData, una vez integrada se le aplica un análisis estadístico con la finalidad de identificar el efecto de los componentes principales; mientras que en la fase III, se determina la configuración de la Red Neuronal Artificial Monocapa o Multicapa que mejor ajusta los valores observados a los esperados a partir del desempeño de la red; finalmente, en la Fase IV se aplica la herramienta desarrollada en la predicción de nuevos casos y su validación por expertos, conformándose así el sistema experto.

Fase I. Análisis de Variables

Esta fase implica analizar las causas y los factores a nivel nacional que provocan la deserción en el nivel universitario. Según los datos del INEGI en el censo de población realizado en el año 2000, estas son:

- Causas personales, que incluyen a aquellos individuos que no les gusto o no quisieron estudiar.
- Causas económicas, que agrupan a los alumnos que por falta de dinero o porque tenían que trabajar tuvieron que abandonar sus estudios.
- Causas escolares, las cuales indican que los alumnos no continuaron con sus estudios debido a que la escuela estaba muy lejos o no había.
- Causas familiares, que incluye a los alumnos que ya no estudiaron por falta del apoyo familiar, porque ya no los dejaron o porque apoyarían en las tareas del hogar.
- Causa de matrimonio y unión, en la cual se incluyen aquellos estudiantes que debido a que decidieron unir sus vidas con una pareja ya no continuaron sus estudios.
- Otras causas, éstas se pueden deber a diversas circunstancias entre las cuales se pueden incluir los servicios brindados por la institución, la capacidad de entendimiento en los temas abordados, entre otras.

Las anteriores causas se definieron como variables de deserción, siendo estas: carrera, semestre, sexo, número de integrantes de familia, vive con padre, vive con madre, número de hermanos, número de hermanas, número de hijos, compromiso escolar, lugar de nacimiento, estado civil, localidad de nacimiento, trabajo, becado, escolaridad del padre, y escolaridad de la madre. A partir de la identificación de las variables, estas se validaron por expertos (psicólogos, directivos institucionales, docentes, alumnos, padres de familia), quienes establecieron las variables de entrada de interés en: carrera, sexo, número de integrantes de familia, viven con padre, vive con madre, número de hermanos, número de hermanas, compromiso escolar, lugar de nacimiento, estado civil, con quien vivirá durante los estudios, trabaja, profesión del padre, profesión de la madre, tipo de vivienda; siendo la variable de salida "¿continúo estudiando?".

Fase II. BigData y PCA

Con las variables definidas por los expertos, se procedió a conformar la BigData de los expedientes proporcionados por el área de Tutorías del Instituto Tecnológico Superior de Purísima del Rincón (ITSPR), la cual considera 227 expedientes de la matrícula escolar 2015 y 2016, esto debido a que el ITSPR inicia actividades académicas como un Tecnológico desincorporado del Instituto Tecnológico Superior de Irapuato (ITESI) en el año 2014.

Los valores de las variables se codificaron de forma cuantitativa, de manera tal, que estas se analizaran a través del Principal Component Analysis (PCA). El PCA, es una técnica estadística multivariada que analiza la base de datos en la que las observaciones son descritas por las diversas variables dependientes cuantitativas interrelacionadas [17].

El objetivo del PCA, es extraer los patrones dominantes en la matriz en términos de conjuntos complementarios [18], siendo muy probablemente la técnica de reducción de dimensiones más conocida y empleada [19]. Al analizar las correlaciones de la matriz conformada por las observaciones y las variables de entrada, se obtiene el análisis de los valores y vectores propios de la matriz de correlación de la Big Data.

Fase III. Construcción de la ANN

El campo de la AI, emana el intentar hacer pensar a las máquinas, i.e., crear máquinas capaces de reaccionar, ante ciertas circunstancias. La AI, se ocupa entender cómo piensan las máquinas y emular esos comportamientos de manera artificial, a través del desarrollo de máquinas que piense tal y como piensa un humano [20]. El campo de la AI incluye la lógica, probabilidad, y matemáticas continuas; percepción, razonamiento, aprendizaje, y acción; y todo, desde controladores micro-electrónicos hasta exploradores robóticos planetarios [21]. En [20] y [22-24] se presentan algunas de

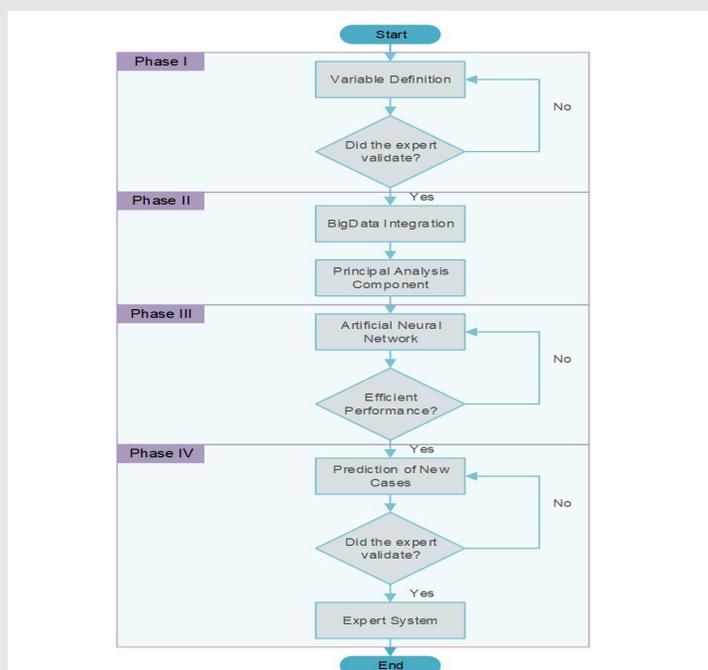


Figura 1. Fases de la metodología empleadas en el desarrollo del Sistema Experto.

las principales técnicas empleadas en el campo de la AI, tales como las Petri Nets, Expert System, Fuzzy Logic, Artificial Neural Networks, Evolutionary Computing, Genetic Algorithms, Genetic Programming y Chaos Theory. Según [25], las técnicas de la AI pueden ser altamente eficientes en el reconocimiento de patrones, realizando regresiones para el propósito de predicciones, y optimizando soluciones para problemas complejos no lineales.

Las ANN's, se desenvuelven en el campo de la clasificación, la predicción, y en la determinación de patrones de comportamiento. Son una herramienta muy recomendable en casos reales, en donde, el procesamiento de información es masiva, imprecisa y distorsionada. Las ANN's, son "... redes computacionales que intentar similar, de forma significativa, las redes de las células nerviosas (neuronas) del sistema nervioso central biológico (humano o animal). Es una simulación célula por célula (neurona por neurona, elemento por elemento). Que toma el conocimiento neuropsicológico de las redes biológicas y de la configuración de las redes" [26].

La aplicación de las ANN's, en la resolución de problemas, es simple, se parte de una base de datos -generalmente históricos-, la cual, típicamente está prescrita en variables de entrada, y variables de salida. Las variables de entrada, están conformadas por los factores y/o parámetros, que influyen significativamente en la(s) variable(s) de salida(s); y la(s) salida(s), es/son el/los factor(es) y/o parámetro(s) que se desea(n) predecir, clasificar y/o determinar su comportamiento. Por lo tanto, el objetivo es entrenar la red, de modo tal que, cuando casos nuevos sean presentados -entradas-, la red prediga el/los factor(es) y/o parámetro(s) deseado(s) -salida(s).

Para el caso bajo estudio, se prueban diversas configuraciones de ANN's evaluando el desempeño de cada una de estas, de manera tal que se determine una red con un desempeño asequible. Las ANN's se desarrollan en Matlab R2019a, empleando una *Feed Forward Back Propagation Net* (FFBPN), al tenerse los valores en la variable de salida, i.e., entrenamiento supervisado; y por consiguiente se emplea como función de entrenamiento el Algoritmo de Retropropagación Levenberg-Marquardt (LM) debido a que actualiza los valores de peso y sesgo; mientras que, como función de aprendizaje de adaptación se emplea un *Gradient Descent with Momentum* (GDM), la cual, considera los gradientes anteriores para suavizar la actualización; y como función de desempeño de la ANN, se establece el *Mean Squared Error* (MSE), como medida promedio de los errores, i.e., la diferencia al cuadrado promedio de los valores estimados y lo que se estima.

Debido a que se entrenan redes multicapa, la Big Data es dividida en tres subconjuntos: el (a) subconjunto de entrenamiento, empleado para calcular el gradiente y

actualizar los pesos y sesgo de la red; el (b) subconjunto de validación, el error de éste subconjunto se supervisa durante el proceso de entrenamiento, ya que cuando la red comienza a sobrentrenarse debido al sobreajuste de los datos, los pesos y sesgos de la red se guardan al mínimo error del subconjunto de validación; y el (c) subconjunto de prueba, el error de éste subconjunto no se emplea durante el entrenamiento, sin embargo es posible emplearlo para comparar diferentes modelos. Generalmente las proporciones para el entrenamiento, validación y prueba son del 70%, 15% y 15%, respectivamente [27].

Fase IV. Predicción de Nuevos Casos

La última fase comprende la implementación del sistema experto; para lo cual se extrae una muestra aleatoria representativa de la población bajo estudio, casos que no forman parte del entrenamiento, validación y prueba de la ANN. De los nuevos casos, se registra la información pertinente a las variables de entrada; para cada caso se predice la variable de salida, la cual a su vez es comparada con la salida real para cada caso.

RESULTADOS

La aplicación de la *Fase I*, permitió determinar según los expertos las variables involucradas en la deserción escolar, a partir de los factores del INEGI (personales, económicas, escolares, familiares, de matrimonio y unión, y otras causas). Teniendo así un total de 17 variables; siendo 16 variables de entrada (carrera, sexo, número de integrantes de familia, viven con padre, vive con madre, número de hermanos, número de hermanas, compromiso escolar, lugar de nacimiento, estado civil, con quien vivirá durante los estudios, trabaja, profesión del padre, profesión de la madre, tipo de vivienda) y 1 variable de salida binaria (¿continúo estudiando?). El considerar la apreciación de los expertos en la determinación de las variables de interés, permite robustecer las variables a considerar por el sistema experto.

En la *Fase II* son definidas las variables de entrada y salida, integrada con la información de 227 expedientes de la matrícula escolar 2015 y 2016 del ITSPR; expedientes proporcionada por el Departamento de Tutorías. Al aplicarse el PCA sobre la BigData, se identifican los componentes principales de las variables que representan patrones de comportamiento en la deserción escolar, e.g., en la Figura 2 se muestran las influencias de los dos primeros componentes principales, empleando Minitab 2018.

Algunos factores que influyen significativamente en la deserción escolar, en el ITSPR son:

- Carrera (Carrera Profesional). Implica los resultados de la interacción entre la planeación de las metas relacionadas con el trabajo y la educación [28].
- Sexo. Viene determinado por la naturaleza, es una construcción natural, con la que se nace [29].
- Número de integrantes de familia. Es un conjunto de

individuos unidos por un parentesco [30].

- Compromiso. Es el desarrollo de actos o acciones para concretar acuerdos y brindar confianza para presentar respuestas favorables [31].
- Estado civil. Es la situación personal en que se encuentra o no una persona física en relación a otra, con quien se crean lazos jurídicamente reconocidos [32].
- Padre y Madre. Es compartir un proyecto de vida en la cual se explora todo lo relacionado con el desarrollo personal de sentimientos asociados a una necesidad de formar una familia [33].

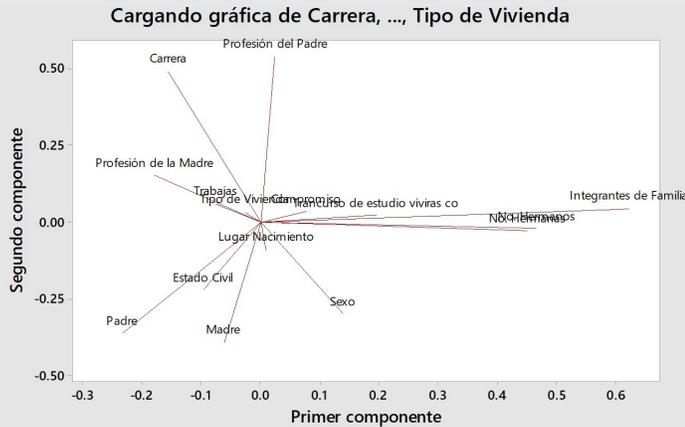


Figura 2. Gráfica de carga para los 2 primeros componentes.

En la Fase III, a partir de la información obtenida por el PCA, son probadas diversas configuraciones de ANN's que mejor ajusten los valores observados a los esperados a partir del desempeño de la red. La configuración que presentó mejor desempeño resultó ser una ANN multicapa: (a) una capa de entrada, la cual contiene las variables de entrada de interés; (b) tres capas ocultas, con 10 neuronas en la primera, 20 neuronas en la segunda y 20 neuronas en la tercera; y finalmente, (c) una capa de salida, que contiene la variable de salida de interés. En la Figura 3, se presenta el desempeño de la mejor red encontrada; el estado del entrenamiento registrado por la red se muestra en la Figura 4; mientras que la regresión lineal de los estimados en relación a lo que se estima, se presenta en la Figura 5.

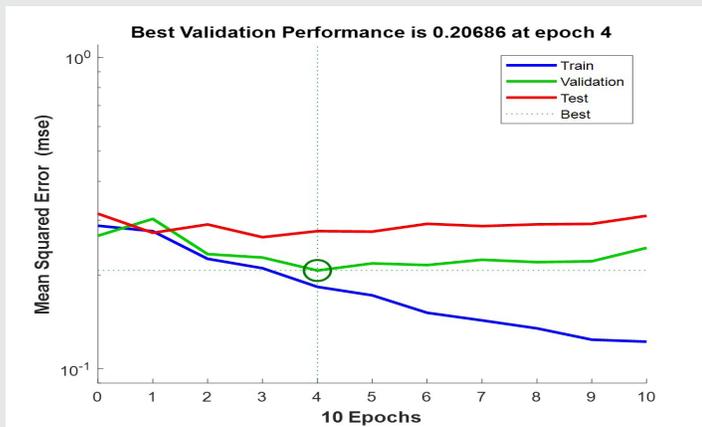


Figura 3. Desempeño de la red.

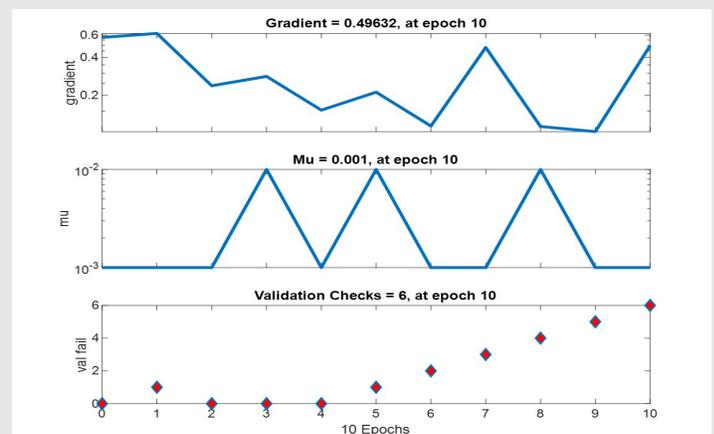


Figura 4. Desempeño durante el entrenamiento.

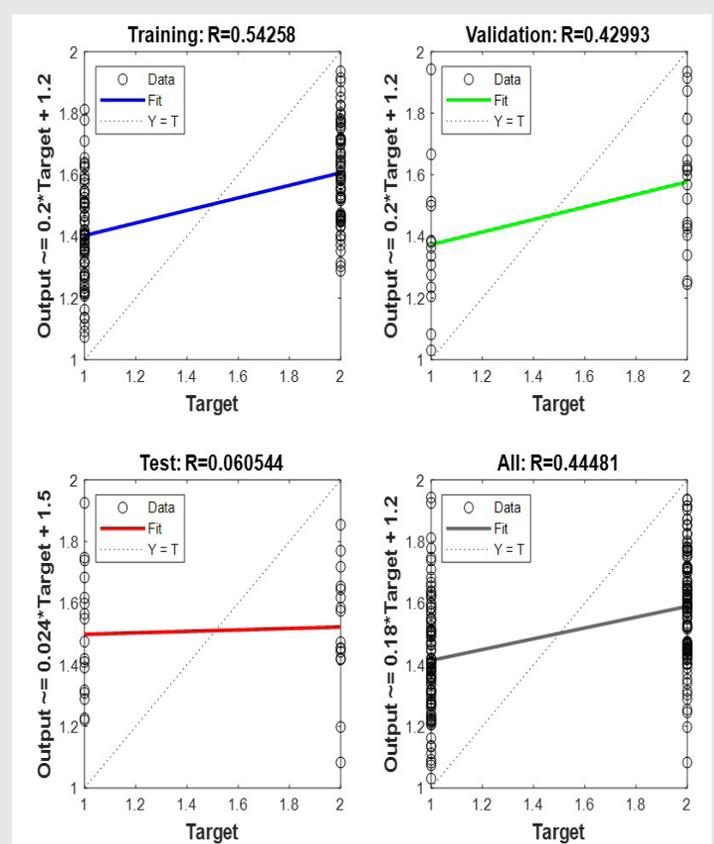


Figura 5. Regresión lineal de los estimados y lo que se estima

Finalmente, en la Fase IV el sistema experto desarrollado es implementado, y al mismo tiempo es validado por los expertos en el comportamiento de la deserción escolar. En la Figura 6 se presentan los estimados y lo que se estima por la red, en esta gráfica se aprecia una eficiencia del 90.90% de la red en la predicción de la deserción escolar en 88 casos. Finalmente, en la Figura 7 se presentan las variables que influyen significativamente en la deserción escolar universitaria; siendo las principales: con quien vivirá durante el transcurso de los estudios, estado civil y la carrera seleccionada, representando el 83.02% que describen dicho patrón de comportamiento del caso bajo estudio.

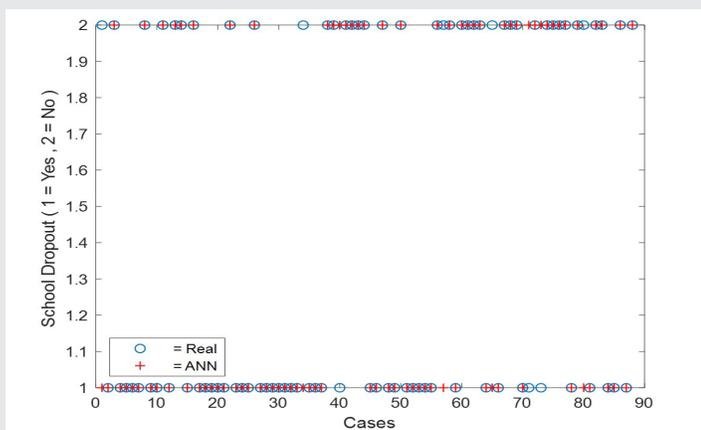


Figura 6. Desempeño del Sistema Experto en la predicción de nuevos casos.

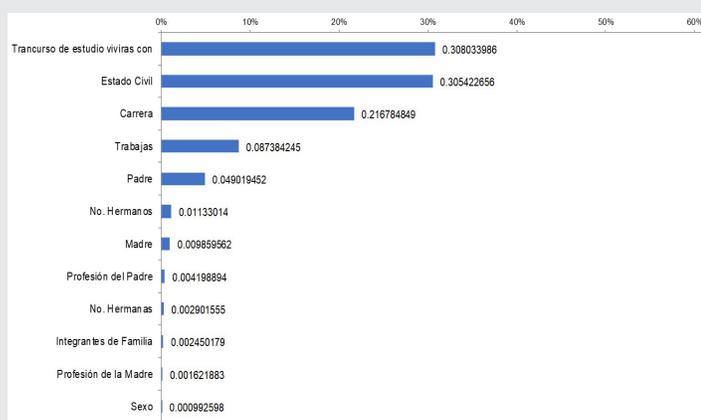


Figura 7. Variables de Impacto de la BigData.

CONCLUSIONES

El sistema experto inteligente desarrollado basado en una ANN multicapa y robustecido por el conocimiento de los expertos en deserción escolar, para predecir si un estudiante deserta o no del sistema del TecNM, a partir de las variables descriptivas del mismo es viable y eficiente, al presentar un desempeño en las predicciones ante nuevos casos del 90.90%. El empleo de la metodología propuesta, donde el sistema considera la experiencia de los expertos durante todo el proceso de diseño, desarrollo e implementación; valida en cada fase, el sistema experto. Al mismo tiempo, el estudio permite identificar que para el sistema del ITSPR existen 16 variables que según los expertos influyen en la decisión de un estudiante en continuar o no con su formación académica.

Con la implementación del sistema experto inteligente se da apoyo al Departamento de Tutorías de la IES bajo estudio, con lo que se establecen estrategias adecuadas, e.g., talleres de autoestima, cursos de nivelación académica, becas, que sirven de apoyo para que el estudiante, finiquite su formación profesional. Desde la implementación del sistema experto inteligente a la fecha se identificaron 20 estudiantes en riesgo de deserción,

de los cuales 18 al ser canalizados se identificó de manera fehaciente que abandonarían su formación profesional; a los estudiantes, identificados se les dio acompañamiento puntual, y así recibir apoyo de las instancias pertinentes, e.g., beca por parte de Servicios Escolares, apoyo psicológico por el Departamento de Tutorías, asesoría académica por el Departamento de Desarrollo Académico; evitando así que estos desertaran y actualmente continúan con su formación académica.

Es así, que la implementación del sistema experto como herramienta de detección, permite establecer estrategias de seguimiento y retención de estudiantes, para que estos concluyan su formación profesional y así apoyar al desarrollo de la región, del estado y del país. Como trabajo en desarrollo, el sistema se está robusteciendo con Fuzzy Logic, con la finalidad de modelar la subjetividad de los expertos del área del comportamiento en la deserción escolar.

BIBLIOGRAFÍA

[1] CEPAL. (2016). *Agenda 2030 y los Objetivos de Desarrollo Sostenible—Una oportunidad para América Latina y el Caribe*. Santiago, Chile: Naciones Unidas.

[2] Jadue, G. (2002). *Factores Psicológicos que Pre-disponen al Bajo Rendimiento, al Fracaso y a la Deserción Escolar*. *Revista Estudios Pedagógicos*. Valdivia. (28) 193-204.

[3] Paramo, G. & Correa, C. (2012). *Deserción Estudiantil Universitaria—Conceptualización*. *Journal Universidad EAFIT*. 35(114) 65-78.

[4] Román, M. (2013). *Factores Asociados al Abandono y la Deserción Escolar en América Latina: Una Mirada en Conjunto*. *Revista Iberoamericana sobre Calidad, Eficacia y Cambio en Educación*. 11(2) 33-59.

[5] Palacios, J. R. & Andrade, P. (2007). *Desempeño Académico y Conductas de Riesgo en Adolescentes*. *Journal de Educación y Desarrollo*. (7) 5-16.

[6] Moreno, D. M. (2013). *La Deserción Escolar: Un Problema de Carácter Social*. *Journal In Vestigium Ire*. 6 115-124.

[7] Silvera, L. M. (2016). *La Evaluación y su Incidencia en la Deserción Escolar*. *Journal Educación y Humanismo*. 18(31) 313-325.

[8] Herrera, M. (2009). *El Valor de la Escuela y el Fracaso Escolar*. *Revista Iberoamericana sobre Calidad, Eficacia y Cambio en Educación*. 7(4) 254-263.

[9] Zuñiga, M. G. (2008). *Deserción Estudiantil en el Nivel Superior Causas y Solución*. México: Editorial Trillas.

- [10] Pineda, C. (2010). *La voz del Estudiante: el Éxito de Programas de Retención Universitaria*. UNESCO-IESALC. Colombia: UNESCO-IESALC.
- [11] Troussas, C., Chrysafiadi, K. & Virvou, M. (2019). An Intelligent Adaptive Fuzzy-Based Inference System for Computer-Assisted Language Learning. *Journal Expert Systems with Applications*. (127) 85-96.
- [12] Garshasbi, S., Mohammadi, Y., Graf, S., Garshasbi, S. & Shen, J. (2019). Optimal Learning Group Formation: A Multi-Objective Heuristic Search Strategy for Enhancing Inter-Group Homogeneity and Intra-Group Heterogeneity. *Journal Expert Systems with Applications*. (118) 506-521.
- [13] Alberola, J. M., Del Val, M., Sanchez-Anguix, V., Palomares, A. & Teruel, M. D. (2016). An Artificial Intelligence Tool for Heterogeneous Team Formation in the Classroom. *Journal Knowledge-Based Systems*. (101) 1-14.
- [14] Bajaj, R. & Sharma, V. (2018). Smart Education with Artificial Intelligence Based Determination of Learning Styles. *Journal Procedia Computer Science*. (132) 834-842.
- [15] Winkler-Schwartz, A., Bissonnette, V., Mirchi, N., Ponnudurai, N., Yilmaz, R., Ledwos, N., Siyar, S., Azarnoush, H., Karlik, B. & Del Maestro, R. F. (2019). Artificial Intelligence in Medical Education: Best Practices Using Machine Learning to Assess Surgical Expertise in Virtual Reality Simulation. *Journal of Surgical Education*. doi: <https://doi.org/10.1016/j.jsurg.2019.05.015>.
- [16] Chassignol, M., Khoroshavin, A., Klimova, A. & Bilyatdinova, A. (2018). Artificial Intelligence Trends in Education: A Narrative Overview. *Journal Procedia Computer Science*. (136) 16-24.
- [17] Abdi, H. & Williams, L. J. (2010). Principal Component Analysis. *Journal WIREs Computational Statistics*. 2(4) 433-459.
- [18] Wold, S., Esbensen, K. & Geladi, P. (1987). Principal Component Analysis. *Journal Chemometrics and Intelligent Laboratory Systems*. 2(1-3) 37-52.
- [19] Jolliffe, I. (2011). Principal Component Analysis. *Journal International Encyclopedia of Statistical Science*. 1094-1096.
- [20] Nilsson, N. J. (1998). *Artificial Intelligence: A New Synthesis*. San Francisco-California: Morgan Kaufmann Publishers Inc.
- [21] Russell, S. J. & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Ed. 3. Malasya: Pearson Education Limited.
- [22] Vas, P. (1999). *Artificial-Intelligence-based Electrical Machines and Drives: Application of Fuzzy, Neural, Fuzzy-neural, and Genetic-algorithm-based Techniques*. New York: Oxford University Press.
- [23] Bäck, T. & Schwefel, H.-P. (1993). An Overview of Evolutionary Algorithms for Parameter Optimization. *Journal Evolutionary Computation*. 1(1) 1-23.
- [24] Tettamanzi, A. & Tomassini, M. (2013). *Soft Computing: Integrating Evolutionary, Neural, and Fuzzy Systems*. New York: Springer Science & Business Media.
- [25] Haupt, S. E., Lakshmanan, V., Marzban, C., Pasini, A. & Williams, J. K. (2008). Environmental Science Models and Artificial Intelligence, In: Haupt, S. E., Pasini, A. and Marzban, C. *Journal Artificial Intelligence Methods in the Environmental Sciences*. Springer Science & Business Media 3-13.
- [26] Graupe, D. (2013). *Principles of Artificial Neural Networks: Advanced Series on Circuits and Systems*. Singapore: World Scientific Publishing Co. Pte. Ltd.
- [27] MathWorks. (2017). *Neural Network Toolbox—User's Guide*. Massachusetts: The MathWorks, Inc. Natick.
- [28] Caldas, M. E., Castellano, A. & Hidalgo, M. L. (2014). *Formación y Orientación Laboral*. Madrid: Editec.
- [29] Tubert, S. (2003). *Del Sexo al Género, los Equívocos de un Concepto*. España: Cátedra.
- [30] Gomes, C. (2001). *Procesos Sociales, Población y Familia: Alternativa Teóricas y Empíricas en las Investigaciones sobre la Vida Doméstica*. México: Facultad Latinoamericana de Ciencias Sociales.
- [31] Campos, A. (2010). *Violencia Social*. Costa Rica: Editorial de la UNED, ILANUD Naciones Unidas.
- [32] Ochoa, G. & Oscar, E. (2006). *Derecho Civil I: Personas*. Venezuela: Universidad Católica Andrés Bello.
- [33] Givaudan, M. & Pick, S. (2016). *Yo papá, Yo Mamá*. México: Penguin Random House Grupo Editorial S.A. de C.V.