
Modelo clasificador para personalizar ejercicios propuestos a estudiantes utilizando redes neuronales artificiales

Classifier Model For Personalizing Exercises Given To Students Using Artificial Neural Networks

使用人工神经网络向学生提供的个性化练习的分类器模型

Классификационная модель для индивидуализации упражнений, предлагаемых студентам, с применением искусственных нейронных сетей

Edwar Abril Saire Peralta

Universidad Nacional de San Agustín
esaire@unsa.edu.pe
<https://orcid.org/0000-0002-9526-0205>.

Edwar Andrés Velarde Allazo

Universidad Tecnológica del Perú
evelarde@utp.edu.pe
<https://orcid.org/0000-0002-6639-7632>

Fechas · Dates

Recibido: 2022-08-02
Aceptado: 2022-09-30
Publicado: 2023-01-01

Cómo citar este trabajo · How to Cite this Paper

Saire Peralta, E. A., & Velarde Allazo, E. A. (2023). Modelo clasificador para personalizar ejercicios propuestos a estudiantes utilizando redes neuronales artificiales. *Publicaciones*, 53(2), 89–106. <https://doi.org/10.30827/publicaciones.v53i2.26818>

Resumen

El artículo tiene como objetivo el desarrollo de un modelo que permite predecir en forma personalizada los ejercicios que puede resolver un estudiante, y por otro lado los que no puede resolver. El modelo está basado en una serie de factores que influye en los ritmos de aprendizaje de los estudiantes. El curso que se utilizó como experimento en el proyecto es el manejo de funciones en hojas de cálculo. Para el desarrollo del proceso se ha utilizado la metodología de minería de datos KDD (Knowledge Discovery in Databases) y para el modelo se ha utilizado redes neuronales artificiales con aprendizaje hacia atrás (Backpropagation), el cual es un algoritmo de aprendizaje supervisado. El modelo se alimenta con datos como sexo, edad, grado académico, nivel de instrucción de los padres, tipo de colegio, calificaciones previas de los temas que el estudiante obtiene mientras avanza en el curso. El enfoque de la investigación es de corte cuantitativo, experimental, de tipo aplicada y la población estuvo representada por 85 estudiantes. El resultado muestra que el modelo logra una probabilidad del 72% de precisión al predecir la asignación de ejercicios a los estudiantes según sus características. Los ejercicios que no pueden ser resueltos se les anexa una ayuda para su mejor comprensión y resolución.

Palabras clave: redes neuronales artificiales, aprendizaje supervisado, minería de datos, validación cruzada.

Abstract

The objective of the article is to develop a model that allows to predict in a personalized way the exercises that a student can solve, and on the other hand the exercises that a student cannot solve. The model is based on a series of factors that influence students' learning rates. The course that was used as an experiment in the project is the handling of functions in spreadsheets. For the development of the process, the KDD (Knowledge Discovery in Databases) data mining methodology has been used and artificial neural networks with backward learning (Backpropagation), which is a supervised learning algorithm, have been used for the model. The model is fed with data such as gender, age, academic grade, parents' level of education, type of school, previous grades of the subjects that the student obtains while advancing in the course. The research approach is quantitative, experimental, applied and the population was represented by eighty five students. The result shows that the model achieves a 72% probability of accuracy in predicting the assignment of exercises to students according to their characteristics. Exercises that cannot be solved are given a help for their better understanding and resolution.

Keywords: artificial neural networks, supervised learning, data mining, cross validation.

Аннотация

Цель статьи - разработать модель, позволяющую индивидуализированно прогнозировать те упражнения, которые студент может решить, и, с другой стороны, те, которые он/она не может решить. Модель основана на ряде факторов, влияющих на скорость обучения студентов. Предмет, используемый в качестве эксперимента в проекте, - работа с функциями в электронных таблицах. Для разработки процесса использовалась методология поиска данных KDD (Knowledge Discovery in Databases), а для модели - искусственные нейронные сети с обратным распространением, которые являются алгоритмом контролируемого обучения. В модель вводятся такие данные, как пол, возраст, академический курс, уровень образования родителей, тип школы, предыдущие оценки по предметам, полученные студентом при прохождении курса.

Исследовательский подход является количественным, экспериментальным, прикладным, а выборка была представлена 85 студентами. Результат показывает, что модель достигает 72% вероятности точности в предсказании назначения упражнений студентам в соответствии с их характеристиками. Упражнения, которые не удается решить, снабжены подсказкой для их лучшего понимания и решения.

Ключевые слова: контролируемое обучение, добыча данных, искусственные нейронные сети, кросс-валидация.

概要

本文的目标是开发一个允许以个性化的方式预测学可以解决的练习以及无法解决的练习的模型。该模型基于一系列影响学生学习率的因素。在项目中用作实验的课程是电子表格中函数的处理。对于流程的开发,使用了KDD (数据库中的知识发现) 数据挖掘方法,并使用了具有反向学习(反向传播)的模型人工神经网络,这一监督学习算法。该模型输入的数据包括性别、年龄、学业成绩、父母的教育水平、学校类型、学生在课程中取得的先前科目资格。研究方法是定量的、实验性的、应用型的,研究对象为85名学生。结果表明,该模型在预测根据学生的特征分配给学生的练习时,准确率达到了72%。无法解决的练习附有帮助,以便更好地理解 and 解决。

关键词: 监督学习, 数据挖掘, 人工神经网络, 交叉验证。

Introducción

El proceso de enseñanza aprendizaje es integral según Anijovich y Cappelletti (2017) señalan que, si las condiciones de los estudiantes siempre son diferentes, como los ritmos, las formas de aprendizaje y los puntos de partida de cada estudiante, entonces, lo que se aprende y lo que se evalúa no puede estar estandarizado, sino que debe ser diferenciado de acuerdo con la caracterización individual. Méndez (2007) indica que el estudiante procesa la información acorde a su capacidad, motivación, ambiente y la guía que el docente le brinde en su aprendizaje. Los ritmos de aprendizaje tienen vinculación con el rendimiento académico, el cual es determinado por factores personales, familiares, sociales, educativos, tal como lo señalan Medina et al. (2018) y Saucedo et al. (2014). Una sesión de aprendizaje dentro del aula está representada por varios momentos, uno de ellos representa la práctica, el cual mayormente apunta a que los estudiantes resuelvan ejercicios respecto al tema desarrollado. Se ha observado que muchos estudiantes tienen dudas y ciertos temores al interactuar con nuevos temas de aprendizaje, son estudiantes que les cuesta adaptarse al ritmo de avance que impone la mayoría de estudiantes e incluso el docente. Esta realidad se ha visto reflejada a través de los resultados en las evaluaciones del curso de funciones, el cual ha mostrado estudiantes con promedios bajos, abandonos de curso y estudiantes desaprobados. Anaya-Durand y Anaya-Huertas (2010) proponen que el docente debe trabajar en un nivel moderado de exigencia, que no ocasione desaliento y bajas notas. Según Tourón et al. (2014) indica que es un error utilizar los mismos contenidos, ritmos y evaluación a los estudiantes, esto supone un problema ya que pueden llegar a ocasionar frustraciones y que influye al relacionarse con otros estudiantes. La problemática descrita es muy común que se presente en las aulas, y en muchas investigaciones han utilizado predicciones para buscar las formas más idóneas de conocer

el perfil del estudiante en base a ciertos factores y así poder colaborar proponiendo soluciones que ayuden.

Trabajos relacionados

Los trabajos relacionados y previos a la investigación se caracterizan por el hecho de usar uno o más algoritmos de clasificación. Algunas investigaciones usan como datos de insumos/entradas aquellos rastros o interacciones que dejan los estudiantes en las plataformas virtuales como Moodle; otras investigaciones utilizan como insumos/entradas datos que son recolectados a través de instrumentos y que son diseñados en forma personalizada para la investigación y finalmente también existen las investigaciones que utilizan datos que son recolectados a lo largo de los años en sistemas de inscripciones y matrículas. Se ha revisado la literatura y se observa escenarios para hacer predicciones con datos que surgen del proceso de enseñanza aprendizaje y que son determinantes en la predicción del rendimiento académico de los estudiantes. En la Tabla 1 podemos ver un resumen de trabajos relacionados a la investigación.

Tabla 1

Resumen de trabajos previos

Autores	Título	Contribución	Oportunidades de mejora
(Otero et al., 2019)	Tic para la educación: sistema adaptativo basado en mecanismos de aprendizaje automático para la apropiación de tecnologías en estudiantes de educación media	Se construyó un sistema que posibilita las recomendaciones iniciales de contenidos educativos adecuado a las características individuales de estudiantes, administrados según el desempeño de los mismos y las características propias del territorio	El sistema tuvo como alimentación datos recolectados de cursos virtuales, tanto de estudiantes como educadores. La analítica de datos y aprendizaje automático para hacer predicciones y recomendaciones iniciales se ve limitado cuando el proceso de enseñanza aprendizaje es presencial, ya que no se dispone de muchos datos como en el proceso virtual. Una alternativa de mejora para recolectar datos, es analizar las grabaciones de la clases presenciales y extraer patrones de comportamiento.

Autores	Título	Contribución	Oportunidades de mejora
(Salgado Reyes et al., 2019)	Modelo para predecir el rendimiento académico basado en redes neuronales y analítica de aprendizaje	Se propuso un modelo predictivo de rendimiento académico usando datos proporcionados por un sistema de interacción virtual con los estudiantes, se usó analíticas de aprendizaje a través de redes neuronales artificiales, se encontró patrones que fueron determinantes en el rendimiento académicos de los estudiantes.	Los datos recolectados y usados para hacer las predicciones, son del sistema virtual de cursos que poseen, sin embargo queda la oportunidad de mejora si se incluye datos personales, sociales y otros de interés de la investigación.
(Menacho Chiok, 2017)	Predicción del rendimiento académico aplicando técnicas de minería de datos	Muestra un abanico de predicciones para clasificar (aprobado, desaprobado) a los futuros estudiantes matriculados en un curso. Se utilizaron técnicas de minería de datos y se compararon los resultados usando regresión logística, arboles de decisión, redes neuronales y redes bayesianas. Se logró una efectividad de predicción de 70%.	Para lograr la clasificación se usaron los datos académicos de los estudiantes matriculados en el curso de Estadística General de la UNALM, sin embargo, los factores o variables predictores se seleccionaron en base a los datos que ya poseían, sin tomar en cuenta según investigaciones que existen variables muy influyentes en el rendimiento académico, el cual no se contaba con esto en su investigación.
(Gutiérrez Cárdenas & Casafranca Aguilar, 2015)	Implementation of a Computerized Assessment System by using Backpropagation Neural Networks with R and Shiny	Mediante el uso de redes neuronales artificiales se creó un entorno de atención a las necesidades de cada estudiante con el uso de materiales correctos a través de ejercicios en su evaluación. Esto permite disminuir la sensación de insatisfacción y evitar en muchos casos el abandono de los cursos.	Se han utilizado datos generados por el mismo proyecto. Los resultados obtenidos fueron diferentes niveles de dificultad para los estudiantes en los ejercicios, sin embargo queda el espacio por cubrir para analizar otros factores determinantes y tomar en cuenta los niveles alcanzados por estudiantes en el tema anterior, ya que este proceso es cambiante.

Problemática


Los estudiantes en los centros educativos se caracterizan por ser únicos, singulares y pertenecer a grupos heterogéneos. En cada sesión de aprendizaje el docente trata de mejorar su trabajo con los estudiantes, en especial al desarrollar la parte práctica, donde es común que el docente proponga un conjunto de ejercicios durante la clase, en el cual se presenta casos donde los estudiantes deben resolverlo individualmente y en un determinado tiempo. Taurón y Santiago (2015) indican que un modelo de escuela donde los docentes enseñan los mismos contenidos, con un mismo nivel de complejidad y a una velocidad para toda la clase, esta escuela no está atendiendo a las necesidades diferenciales de los estudiantes. Se ha observado durante las clases que los estudiantes al resolver el conjunto de ejercicios necesitan apoyo, tutoría, ayuda en fórmulas, en su aplicación y sintaxis de las funciones a utilizar. El docente se enfrenta regularmente a dos situaciones las cuales son: primero cuando el estudiante pide ayuda o tutoría al docente, el tiempo siempre es apremiante y no se puede atender a todos ni dedicarle un tiempo adecuado a cada estudiante y, segundo muchos estudiantes necesitan ayuda pero no la solicitan. La diversidad se puede entender como la variedad de estudiantes que existen dentro de nuestras aulas. Cada estudiante es diferente en género, cultura, ritmos de aprendizaje, modos de pensamientos, en sus limitaciones o posibilidades físicas, discapacidades (Méndez, 2017).

Propuesta

Para abordar el problema planteado se ha implementado un modelo que permite predecir la asignación de ejercicios a los estudiantes en forma individualizada, proporcionando ayuda textual en los ejercicios que el estudiante no puede resolver. En la propuesta se implementó un modelo predictivo basado en redes neuronales artificiales. Este sistema de redes neuronales artificiales logra establecer una conexión o relación entre las entradas y salidas, el cual tiene un comportamiento parecido al cerebro humano, donde la información se procesa en paralelo, con el objeto de aprender y generalizar resultados (Singhal & Swarup, 2011). El Modelo propuesto tiene como entrada factores personales, sociales y notas de rendimiento académico de los estudiantes, los cuales fueron recolectados durante varios meses. La minería de datos permite obtener modelos analíticos que descubren patrones y tendencias interesantes en la información de uso del estudiante (Romero et al., 2008). En la Figura 1 se muestra el esquema de la propuesta.

Figura 1

Estructura del Modelo



Población

Los estudiantes que participaron en la investigación llevaron el curso de funciones en hojas de cálculo a un nivel básico, este tipo de curso tiene una duración de un mes con sesiones de lunes a viernes de una hora y media cronológica. Los temas que se desarrollaron en el curso son operadores matemáticos, funciones matemáticas, funciones estadísticas, entre otros. Son 8 temas que se abordaron en el curso y son temas 100% prácticos, es decir, en todo momento se hace uso de la computadora. Los grupos de estudio son heterogéneos y no hay prerrequisito alguno para llevar el curso. El grupo puede estar formado por estudiantes de 15 a 70 años, con niveles de instrucción que van desde la secundaria hasta posgrado y muchos pueden trabajar o estar desocupados. En total se trabajó con 85 estudiantes como población, el cual representa también la muestra.

Datos del cuestionario

Se construyó un instrumento basado en la técnica de la encuesta. Para la elaboración del instrumento cuestionario se revisó la literatura sobre aquellos factores que influyen en los estudiantes en el manejo de los temas de funciones, además de agregar otros factores contextualizados al problema que se aborda. El rendimiento académico, por ser multicausal, pueden agruparse en determinantes sociales, personales e institucionales tal como lo indica Garbanzo Vargas (2007). Uno de los aspectos determinantes para el éxito en el curso de hojas de cálculo fue determinar si el estudiante tenía preferencias por la matemática o poseía habilidades numéricas, por la coyuntura del tiempo y tener cero datos, se hizo una pregunta basada en la escala de likert, preguntándole ¿En qué medida te consideras una persona con habilidades numéricas?, las alternativas para esta pregunta fueron mucho, regular, poco y nada. Esta pregunta fue recomendada por el pedagogo y psicólogo con el que apoyo en la investigación. En la Tabla 2 se muestra los factores que se tomaron en cuenta para el cuestionario.

Tabla 2

Clasificación de los atributos

Tipo	Atributo
Individuales	Edad, sexo, estado civil
	Persona con habilidades numéricas
	Te enseñaron computación en el colegio
Académicos	Experiencia manejando Excel
	Grado académico
	Cuántas horas diarias estudias
Institucionales	Tipo de colegio
	Ocupación actual
	Cuántas horas diarias trabajas
Socioeconómicos	Nivel de instrucción del padre
	Nivel de instrucción de la madre
	Motivo por el cual estudias Excel

Se validó el instrumento con un psicólogo en Educación y un profesional en Ciencias de la Educación, se calculó la confiabilidad del instrumento aplicando el alpha de cronbach, donde el resultado fue .733, el cual representa un valor con denominación de bueno en confiabilidad. Con la validez y confiabilidad obtenida se procedió a aplicar el cuestionario a 85 estudiantes que llevaron el curso.

Datos de evaluación

La recolección de datos respecto a la evaluación representa datos de 85 estudiantes. Las notas de evaluación es un indicador que determina el rendimiento académico de los estudiantes, tal como lo señala Cueto (2006), donde indica que el rendimiento académico es el nivel de conocimiento que tiene un estudiante y se refleja en una nota numérica, el cual mide el resultado del proceso enseñanza aprendizaje, donde el estudiante participa. Se preparó por cada uno de los 8 temas del curso, ejercicios idóneos abarcando los fundamentos de los temas y los objetivos a cumplir. Por cada tema se diseñó 10 tipos de ejercicios. En total se preparó 80 tipos de ejercicios. El levantamiento de información se hizo durante varios meses, ya que cada grupo normalmente estuvo formado por un promedio de 10 estudiantes. Se trabajó con 9 grupos y se aplicó los tipos de ejercicios diseñados en cada tema, se hizo el levantamiento de los tipos de ejercicios que puede resolver y los que no puede resolver cada estudiante del grupo.

Metodología

Para desarrollar la propuesta se siguió el proceso de minería de datos KDD (Knowledge Discovery in Databases), como lo señala Hernández et al. (2004), el cual está representada por cinco etapas. El proceso KDD se define como un proceso de extracción de información útil, de patrones o tendencias dentro de grandes volúmenes de datos, incluso relacionados a big data (Londhe et al., 2013). Dentro de la etapa de minería de datos se trabajó con el algoritmo de clasificación llamado redes neuronales. Es cierto que para desarrollar un aprendizaje automático se necesita mayor cantidad de datos, sin embargo, la institución educativa donde ha ocurrido la investigación, no contaba con ningún dato de sus estudiantes respecto a su perfil y evaluaciones académicas como se requería para dicha investigación. Se inició parte del trabajo aplicando el cuestionario a los nueve grupos, se diseñó los 80 tipos de ejercicios y se aplicó los tipos de ejercicios a cada grupo por varios meses. Todo este proceso de recolección de datos desarticuló el proceso tradicional de evaluación que existía en la institución educativa. En la Figura 2 se muestra las etapas del proceso de minería de datos.

Fase de integración y Recopilación

Se unieron dos fuentes de datos que se recolectaron. La primera fuente de datos se obtuvo al aplicar el cuestionario a los estudiantes que se matricularon en el curso. En la Figura 3 se muestra parte de los datos recolectados.

La segunda fuente de datos que se recolectó estuvo formada por los datos de evaluación (se registró por cada tema y tipo de ejercicio si el estudiante pudo o no pudo resolver el ejercicio). En la Figura 4, podemos ver parte de las evaluaciones registradas. El valor 1 indica que un estudiante pudo resolver un tipo de ejercicio y el valor 0 indica que el estudiante no pudo resolver dicho tipo de ejercicio. Como se mencionó

por cada tema se diseñaron 10 tipos de ejercicios, los cuales fueron etiquetados con las letras A, B, C, D, E, F, G, H, I, J.

Figura 2
El proceso KDD

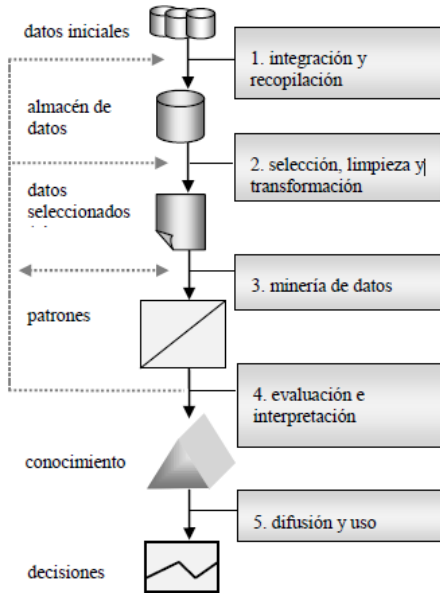


Figura 3
Datos de los estudiantes

1	codigo	edad	sexo	EstadoCivil	cant hermanos	eres una persona con habilidades numericas	tipo de colegio	te enseñaron computo en el colegio
3	1	19	Femenino	Soltero	1	Regular	Particular	Regular
4	2	29	Femenino	Soltero	1	Regular	Nacional	Poco
5	3	25	Femenino	Soltero	4	Regular	Nacional	Poco
6	4	17	Femenino	Soltero	5	Regular	Particular	Regular
7	5	23	Femenino	Soltero	3	Regular	Nacional	Poco
8	6	25	Femenino	Soltero	3	Regular	Nacional	Nada
9	7	21	Masculino	Soltero	1	Regular	Nacional	Poco
10	8	22	Femenino	Soltero	1	Mucho	Particular	Regular

Figura 4
Evaluaciones registradas

CodEstudiante	Tema 01										Tema 02										Tema 03										Tema 04										Nota4	
	A	B	C	D	E	F	G	H	I	J	Nota1	A	B	C	D	E	F	G	H	I	J	Nota2	A	B	C	D	E	F	G	H	I	J	Nota3	A	B	C	D	E	F	G		H
1	1	0	1	1	1	1	1	1	1	0	16	1	1	1	1	1	0	1	1	1	18	1	0	1	1	1	1	1	1	0	16	1	1	1	1	1	1	1	1	1	1	20
2	1	1	1	1	0	1	1	1	1	1	18	1	1	1	0	1	0	1	1	1	16	1	1	1	1	1	1	1	1	1	20	1	1	1	1	1	1	1	1	1	1	20
3	1	0	1	1	0	1	1	1	1	0	14	1	1	0	1	1	1	0	0	0	12	0	1	1	1	1	0	1	1	0	14	1	1	1	0	0	1	0	0	0	0	10
4	0	1	1	1	0	1	0	0	0	0	8	1	1	0	1	1	0	1	1	1	16	1	0	1	1	0	1	1	1	1	16	1	1	1	1	1	1	1	1	1	1	20
5	1	1	1	1	1	1	1	1	1	1	20	1	1	1	0	1	1	1	1	1	18	0	1	1	1	1	1	1	1	1	18	1	1	1	1	1	1	1	1	1	1	20

Fase de selección, limpieza y transformación


La fase de selección implicó el uso de todos los datos del cuestionario con la totalidad de los registros recolectados. La fase de limpieza se aplicó en las evaluaciones con estudiantes que no tenían notas de evaluación, debido a que faltaron uno o más días de evaluación. Finalmente, en la fase de transformación todos los datos del cuestionario se codificaron numéricamente para poder procesar los datos, utilizando en algunos casos variables binarias de tipo Dummy. El único campo calculado fue la nota final de cada tema, debido a que cada tipo de ejercicios valía 2 puntos y eran 10 tipos, el valor de la nota oscilaba entre 0 y 20. Las dos fuentes de datos fueron integradas y relacionadas. Finalmente, los datos fueron escalados, ya que existían valores que mostraban sesgos.

Fase de minería de datos

La técnica de minería de datos que se aplicó al proyecto propuesto es la de clasificación. Se separaron los datos recolectados, donde el 92% se asignaron para el entrenamiento y el 8% para la validación del modelo. Se utilizó el algoritmo de Redes Neuronales Artificiales con aprendizaje supervisado Backpropagation. Inicialmente los pesos asignados a las variables de entradas (capa de entrada) fueron al azar, los cuales fueron determinados por la Red Neuronal Backpropagation. Este algoritmo logra que las salidas de error se propaguen hacia atrás, partiendo de la capa de entrada replicándose hacia todas las neuronas de la capa oculta y contribuyendo directamente a la salida, al final todas las neuronas reciben una señal de error el cual contribuye al error total y se actualizan los pesos (García et al., 2003). Para obtener el modelo predictivo se utilizó la herramienta gratuita basada en Redes Neuronales artificiales, el cual se denomina "Simbrain". En la Figura 5 se muestra la topología de red para el primer tema.

Figura 5

Topología del primer tema




Layer 1 representa a la capa de entrada (15 atributos del cuestionario), Layer 2 representa la capa oculta con 20 neuronas y finalmente Layer 3 representa la capa de salida con 10 respuestas. Para entrenar el modelo para el segundo tema (funciones matemáticas), la topología debe tener ahora 16 entradas, la cual representa los 15 datos del cuestionario respecto al estudiante y la nota que se obtuvo por el rendimiento

académico del tema anterior (primer tema) y así sucesivamente aumentará las entradas para los demás temas. Lo mismo sucederá si entrenamos el modelo para el último tema (funciones de búsqueda), donde las entradas fueron 15 datos del cuestionario más las 6 notas de cada uno de los temas previos. En cada tema se va acumulando la nota del tema previo y así sucesivamente, esto debido a que la nota que obtiene un estudiante en el tema previo influye decisivamente en la nota de evaluación del tema siguiente. Existen numerosas investigaciones como las de Betts y Morell (1999), Porto y Gresia (2001) y Naylor y Smith (2004) han encontrado evidencia de que el desempeño previo de su rendimiento académico podría condicionar los resultados futuros. En la Figura 6 se muestra el diagrama de redes propuesto para el primer tema.

Figura 6

Diagrama propuesto. Fuente: Gráfico generado con la herramienta Simbrain



Los pesos se inicializan aleatoriamente y se inicia el proceso de aprendizaje o entrenamiento de la red neuronal. En todo momento se buscó que el error fuera mínimo y se comenzó a buscar la mejor topología, haciendo muchas pruebas y modificando sus parámetros de ajuste. Los pesos finales se obtuvieron en base a pruebas, tal como muestra en la Figura 7, usando la herramienta Simbrain.

Con los pesos determinado el modelo ya pudo hacer predicciones con respecto al primer tema, donde un estudiante nuevo que proporcione sus datos por medio del cuestionario, se puede ver qué tipo de ejercicios puede resolver y que tipo de ejercicio no puede resolver. En la Tabla 3 se muestra la cantidad de entradas, neuronas y salidas por cada capa del modelo para los primeros cinco temas.

Figura 7

Pesos de las neuronas del modelo

#	Neuron_16	Neuron_17	Neuron_18	Neuron_19	Neuron_20	Neuron_21	Neuron_22
Neuron_1	-2.5468686...	-6.7358700...	-1.2500194...	-4.0237875...	-1.0537745...	-7.1830402...	13.263154...
Neuron_2	1.5280421...	-3.7007524...	1.1490117...	-4.0832765...	9.6462547...	6.1628328...	7.1827073...
Neuron_3	-6.7114719...	8.6319200...	0.0256459...	0.0686249...	-1.1546985...	0.2023922...	0.6873477...
Neuron_4	0.1522153...	4.5581121...	2.8430765...	0.9717167...	5.7112917...	-3.4814065...	0.9283591...
Neuron_5	-2.8148780...	9.5564373...	0.5752059...	2.9482481...	3.1157402...	6.1367483...	7.8593134...
Neuron_6	0.6756623...	0.3150097...	-0.8997563...	-4.8103435...	-6.9550492...	9.9645840...	-11.98390...
Neuron_7	3.8851304...	-6.8118809...	-3.2610071...	-0.2625445...	-4.1443163...	-2.0591709...	6.0518174...
Neuron_8	2.9317069...	4.3304776...	2.4847936...	-5.8872260...	6.4363969...	9.9843602...	3.3970491...
Neuron_9	-1.9895990...	4.7668451...	3.4832447...	8.7176471...	-7.7326392...	10.3586650...	0.5477307...
Neuron_10	1.3826432...	-0.4028418...	-4.6407271...	-3.7071017...	-3.1123237...	-3.8242243...	3.0688672...
Neuron_11	2.0039972...	3.2076531...	1.3461279...	10.690974...	-1.7129278...	-3.5633561...	3.3659328...
Neuron_12	-7.8066351...	0.9760955...	-0.3567500...	-4.0558211...	-9.2608831...	-2.7175812...	5.2736138...
Neuron_13	1.6796499...	-2.7012623...	-0.1975588...	-0.7658859...	6.5463030...	-9.2329547...	-6.617524...
Neuron_14	-3.8028446...	-1.1405232...	-1.9342247...	7.4752330...	2.2358516...	1.3089843...	-10.39941...

Tabla 3

Topología final del modelo propuesto

Tema	Capa de entrada	Capa oculta	Capa de salida
Tema 01	15	20	10
Tema 02	16	30	10
Tema 03	17	20	10
Tema 04	18	20	10
Tema 05	19	20	10

Fase de Evaluación e Interpretación

Con el 8% de los registros que fueron separados inicialmente se hizo la validación, ingresando al modelo datos que nunca vistos. Los resultados se muestran en la Tabla 4 respecto al primer tema. Recordemos que el valor 1 representa que el estudiante sí pudo resolver el ejercicio y el valor 0 representa que el estudiante no pudo resolver el ejercicio. La predicción basada en el 8% de estudiantes tuvo una precisión aproximada del 72%.

Fase Difusión y uso

Al término de la evaluación tanto los docentes como los estudiantes mostraron satisfacción con los resultados, ya que se logró una asertividad del 72%. La fortaleza del modelo es identificar aquellos tipos de ejercicios donde los estudiantes muestran dificultad, y es en este espacio donde se apoyará al estudiante.

Tabla 4

Predicción del modelo para los estudiantes

Estudiante	Resultado del modelo	Resultado esperado	Predicción acertada
1	1111111111	1111011100	70%
2	1111111111	1111011101	80%
3	1110000100	1010000111	70%
4	1011011110	1111111101	60%
5	1111011110	1011011111	80%

Resultados

En base al modelo predictivo obtenido se comprobó su efectividad, seleccionando grupos experimentales (grupo de estudiantes nuevos al curso), el cual se aplicó el modelo predictivo para los dos primeros temas. Además, se seleccionaron grupos de control (grupos de estudiantes nuevos al curso) donde también se desarrollaron los dos primeros temas, pero aplicando modelo tradicional. En total para hacer las pruebas se manejó 3 grupos experimentales y otros 3 grupos de control.

El tipo de curso que se usó para recoger los datos académicos y el tipo de curso donde se probó el modelo final son cursos relacionados a las hojas de cálculo, además los 80 tipos de ejercicios diseñados también están relacionados al manejo de funciones en hojas de cálculo, tales como funciones matemáticas, estadísticas, texto, fecha-hora, lógicas, etc. En la Tabla 5 podemos ver los promedios obtenidos por el grupo experimental, además se ve la cantidad de ejercicios que pudo y no pudo resolver.

Tabla 5

Resultados del grupo experimental

Resultados del Tema 01 aplicando el modelo predictivo - Grupo 1			
Código	Pudo resolver	no pudo resolver	Nota
1	7 de 8	1 de 2	16
2	6 de 8	0 de 2	12
3	8 de 8	2 de 2	20
4	7 de 8	1 de 2	16
5	8 de 8	2 de 2	20
6	7 de 8	0 de 2	14
7	7 de 10	0 de 0	14
8	7 de 8	0 de 2	14
9	8 de 9	0 de 1	16
10	8 de 8	2 de 2	20
11	9 de 10	0 de 0	18
		Promedio	16.3

En la Tabla 6 se muestra los resultados obtenidos del grupo de control.

Tabla 6

Resultados del grupo de control

Resultados del Primer Tema- Grupo1	
Código estudiante	Nota
12	16
13	18
14	20
15	08
16	08
17	14
18	02
19	16
20	14
21	18
22	18
Promedio	13.8

En la Tabla 7 podemos ver los promedios obtenidos por los grupos experimentales y de control donde el promedio aumentó de 13.4 a 17.2.

Tabla 7

Resultados de los grupos

N° de Grupo	N°. de Tema	Experimental	Control
Grupo 01	Tema 01	16.3	13.8
	Tema 02	17.4	12.0
Grupo 02	Tema 01	18.3	15.4
	Tema 02	16.8	12.0
Grupo 03	Tema 01	17.9	15.2
	Tema 02	16.8	12.5
Promedios		17.2	13.4

Para los resultados de la tabla 7 se desarrolló un análisis estadístico Anova, como se muestra en la tabla 8.

Tabla 8

Análisis de Varianza de la tabla 7

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Grupos	1	42.563	42.5633z	81.72	.000
Temas	1	7.363	7.3633	14.14	.006
Grupos*temas	1	3.413	3.4133	6.55	.034
Error	8	4.167	.5208		
Total	11	57.507			

Existe una diferencia Significativa de las notas de los estudiantes, con los resultados del grupo experimental en relación con el grupo de control, como también los temas propuestos en el estudio. Para darle más soporte de confiabilidad al modelo predictivo obtenido, se compararon los promedios de los resultados actuales del modelo predictivo con los promedios de estudiantes de años anteriores, se tomaron las notas de 3 grupos y se vio que el modelo propuesto en la presente investigación mejora los promedios de 13.3 a 16.4. En la Tabla 9 podemos ver los resultados de comparación.

Tabla 9

Resultados de los grupos

Nº	Experimental	Histórico
Grupo 1	16.2	12.8
Grupo 2	17.0	14.0
Grupo 3	16.1	13.1
Promedio	16.4	13.3

En la Tabla 10 podemos ver los resultados Anova de la Tabla 9.

Tabla 10

Resultados de Anova de tabla 9

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Grupos	1	14.7267	14.7267	552.25	.002
Temas	2	1.2133	.6067	22.75	.042
Error	2	.0533	.0267		
Total	5	15.9933			

Al realizar el análisis Anova de los resultados podemos notar una diferencia significativa entre los valores experimentales sobre los históricos.

Discusión y conclusiones

En este apartado indicamos que el modelo predictivo obtenido, no solamente se verificó la precisión con los datos del test, sino que también se ha implementado una aplicación basada en el modelo, dicha aplicación se ha usado en nuevos grupos de estudiantes que llevan el curso de hojas de cálculo, y se logró comprobar la precisión del modelo con una aproximación del 72%. En otras investigaciones relacionadas a este proyecto, la comprobación de precisión de su modelo final, lo hacen con los datos de validación de test (que inicialmente separaron), el cual es parte de la muestra de la investigación. No obstante, en este trabajo se buscó estudiantes nuevos (fuera de la muestra) para verificar la precisión del modelo. Los resultados fueron sólidos en cuanto a la comprobación de su precisión.

Según Menacho Chiok (2017) en su trabajo de predicción del rendimiento académico obtuvo una predicción promedio al 70% con la red de Naive de Bayes entre otros algoritmos que probó. Fue determinante en sus resultados la cantidad de estudiantes, ya que contó con 914 estudiantes, los cuales fueron recolectados en dos años, por otro lado, es importante mencionar que la calidad de los datos tiene mucha influencia frente a la cantidad de datos. Muchas veces los datos que recogen las instituciones educativas a lo largo de los años, no tiene la dirección para que dichos datos puedan ser usados en investigaciones de predicciones de rendimiento académico. Los datos en muchos casos solo son registrados como estadística o para copias de seguridad. Otra comparación relacionada es la predicción de Salgado et al. (2019) donde utilizaron redes neuronales e hicieron una predicción sobre los datos encontrados en la plataforma virtual Moodle de 300 estudiantes con un 75% de precisión. La variación, la calidad y la cantidad de datos son una alternativa determinante para ampliar y dar otro enfoque a las investigaciones.

En base a la experiencia conseguida en esta investigación, señalamos que, para poder obtener modelos predictivos más eficientes se debe trabajar, no solo con una mayor cantidad de observaciones o datos de estudiantes, sino además que las variables predictoras deben ser de calidad y deben tener un impacto significativo en la variable dependiente. Para seleccionar la calidad de las variables predictoras se debe tomar en cuenta criterios de un experto en dicha disciplina. Otro criterio importante para seleccionar las variables más significativas es tomar como referencia y aval otras experiencias e investigaciones que aborden temas relacionados. Muchas instituciones educativas poseen datos en sus sistemas virtuales como lo indican Timarán-Pereira (2019) y Zarate-Valderrama (2019), el cual son recolectados a lo largo de muchos años, sin embargo, existe una brecha entre la cantidad de estos frente a la calidad de datos, esta reflexión está relacionada al hecho de que las instituciones educativas deben registrar datos que tengan fuerte impacto y de manera constante para poder usar estos registros y tener investigaciones más completas. El hecho de que las instituciones educativas no registren dichos datos a lo largo de los años, nos vemos en la necesidad de buscar y recolectar los datos, y debido al poco tiempo que se tiene se recolectan muy pocos, y es muy probable que las investigaciones basadas en pocos datos necesiten de más pruebas.

En base a la experiencia obtenida en esta investigación, se recomienda ampliar el modelo para trabajar con ejercicios basados en niveles de complejidad como básico, intermedio y avanzado, donde los ejercicios se asignaran en forma gradual de acuerdo con las capacidades que va mostrando el estudiante a lo largo del desarrollo del curso.

Se ha mostrado que el modelo propuesto se puede utilizar con éxito para predecir los tipos de ejercicios que un estudiante puede resolver y los tipos de ejercicios donde muestra dificultades. El modelo fue expuesto a una validación cruzada para demostrar su solidez, el cual se obtuvo una predicción en un promedio del 72% respecto a los resultados esperados. Se evidenció el aumento del promedio del estudiante de 13.49 a un 17.29 al usar el modelo predictivo, las notas de las evaluaciones de los nuevos grupos de estudiantes usando el modelo se incrementó. En esta investigación el modelo no solo se aplicó a nuevos estudiantes, sino que también se hizo comparaciones de promedios históricos con grupos de la modalidad tradicional de meses anteriores a la investigación, donde el resultado también mostró evidencia del aumento del promedio en sus calificaciones. El modelo obtenido puede mejorarse trabajando con más estudiantes y variables predictoras relacionadas al rendimiento académico.

Referencias

- Anijovich, R., & Cappelletti, G. (2017). *La evaluación como oportunidad*. Paidós.
- Méndez, M. L. (2007). *Diversidad en el aula. Innovación y experiencias Educativas*.
- Medina, N., Ferreira, J., & Marzol, R. (2018). Factores personales que inciden en el bajo rendimiento académico de los estudiantes de geometría. *Telos*, 20(1), 4-28. <https://dialnet.unirioja.es/descarga/articulo/6436353.pdf>
- Saucedo, M., Herrera-Sánchez, S., Díaz, J., Bautista, S., & Salinas, H. (2014). Indicadores de reprobación: Facultad de Ciencias Educativas (UNACAR). *Revista Iberoamericana para la Investigación y el Desarrollo Educativo RIDE*, 5(9), 1-11. <https://doi.org/10.23913/ride.v5i9.7>
- Anaya-Durand, A., & Anaya-Huertas, C. (2010). ¿Motivar para aprobar o para aprender? Estrategias de motivación del aprendizaje para los estudiantes. *Tecnología, Ciencia. Educación*, 25(1), 5-14. <https://www.redalyc.org/articulo.oa?id=48215094002>.
- Tourón, J., Santiago, R., & Díez, A. (2014). *The Flipped Classroom: Cómo convertir la escuela en un espacio de aprendizaje*. Grupo Océano.
- Otero, A., Rivera, W., Pedraza, C., & Canay, J. (2019). TIC para la educación: sistema adaptativo basado en mecanismos de aprendizaje automático para la apropiación de tecnologías en estudiantes de educación media. *Telos: Revista de Estudios Interdisciplinarios en Ciencias Sociales*, 21(3), 526-543. <https://doi.org/10.36390/telos213.03>.
- Salgado Reyes, N., Beltrán Morales, J., Guaña Moya, J., Escobar Teran, C., Nicolalde Rodríguez, D., & Chafla Altamirano, G. (2019). Modelo para predecir el rendimiento académico basado en redes neuronales y analítica de aprendizaje. *Revista Ibérica de Sistemas y Tecnologías de Información*, 1, 258-266. <https://www.proquest.com/openview/5720c78f2e17a27355a8766fe81feb1a/1?pq-origsite=gscholar&cbl=1006393>
- Menacho Chiok, C. H. (2017). Predicción del rendimiento académico aplicando técnicas de minería de datos. *Anales Científicos*, 78(1), 26. <https://doi.org/10.21704/ac.v78i1.811>

- Gutiérrez Cárdenas, J. M., & Casafranca Aguilar, F. (2015). *Implementation of a Computerized Assessment System by using Backpropagation Neural Networks with R and Shiny*. <http://hdl.handle.net/11354/1087>
- Tourón, J., & Santiago, R. (2015). El modelo Flipped Learning y el desarrollo del talento en la escuela. *Revista de Educación*, 368, 196-231. doi: <https://doi.org/10.4438/1988-592X-RE-2015-368-288>
- Singhal, D., & Swarup, K. (2011). Electricity price forecasting using artificial neural networks. *International Journal of Electrical Power & Energy Systems*. Elsevier, 33 (3), pp. 550-555.
- Romero, C., Ventura, S., García, E. (2008). Data mining in course management systems: Moodle case study and tutorial. *Computers and Education*, 51(1), 368-384. <https://doi.org/10.1016/j.compedu.2007.05.016>
- Garbanzo Vargas, G. M. (2007). Factores asociados al rendimiento académico en estudiantes universitarios, una reflexión desde la calidad de la educación superior pública. *Revista educación*, 31(1), 43-64. <https://revistas.ucr.ac.cr/index.php/educacion/article/view/1252>
- Cueto, S. (2006). *Una década evaluando el rendimiento escolar. Organización Grupo de Análisis para el Desarrollo*. GRADE.
- Hernández, O. J., Ramírez, Q. M-J., Ferri, R. C. (2004). *Introducción a la minería de datos*. Person Educación.
- Londhe, S., Mahajan, R., & Bhojar, B. (2013). Survey on Mining High Utility Itemset Transactional Database. *International Journal of Innovative Research & Development*, 2(13), 43-47.
- García Martínez, R., Servente, M., & Pasquín, D. (2003). *Sistemas Inteligentes*. Nueva Librería.
- Betts, J. R., & Morell, D. (1999). The Determinants of Undergraduate Grade Point Average. The Relative Importance of Family Background, High School Resources, and Peer Group Effects. *The Journal of Human Resources*, 34(2).
- Porto, A., & Di Gresia, L. (2001). *Rendimiento de Estudiantes Universitarios y sus Determinantes*. Asociación Argentina de Economía Política.
- Naylor, R. A., & Smith, J. (2004). Determinants of Educational Success in Higher Education. En G. Johnes & J. Johnes (ed.). *International Handbook in the Economics of Education*.
- Timarán-Pereira, R., Caicedo-Zambrano, J., & Hidalgo-Troya, A. (2019). Árboles de decisión para predecir factores asociados al desempeño académico de estudiantes de bachillerato en las pruebas Saber 11°. *Revista de Investigación, Desarrollo e Innovación*, 9(2), 363-378. [10.19053/20278306.v9.n2.2019.9184](https://doi.org/10.19053/20278306.v9.n2.2019.9184).
- Zárate-Valderrama, J., Bedregal-Alpaca, N., & Cornejo-Aparicio, V. (2021). Modelos de clasificación para reconocer patrones de deserción en estudiantes universitarios. *Ingeniare. Revista chilena de ingeniería*, 29(1), 168-177. <http://dx.doi.org/10.4067/S0718-33052021000100168>