



*Asesorías y Tutorías para la Investigación Científica en la Educación Puig-Salabarría S.C.
José María Pino Suárez 400-2 esq a Lerdo de Tejada, Toluca, Estado de México. 7223898475*

RFC: ATI120618V12

Revista Dilemas Contemporáneos: Educación, Política y Valores.

<http://www.dilemascontemporaneoseduccionpoliticayvalores.com/>

Año: IX Número: 3. Artículo no.:9 Período: 1ro de mayo al 31 de agosto del 2022.

TÍTULO: Predicción del rendimiento académico utilizando las primeras actividades académicas de estudiantes universitarios y técnicas de aprendizaje automático.

AUTORES:

1. Dr. Andrés Rico Páez.
2. Máster Nora Diana Gaytán Ramírez.

RESUMEN: El principal objetivo de este estudio es diseñar y evaluar modelos de predicción del rendimiento académico utilizando técnicas de aprendizaje automático y las primeras actividades académicas de estudiantes universitarios. Se recabaron las primeras calificaciones de actividades académicas de 260 estudiantes universitarios para entrenar técnicas de aprendizaje automático para predecir el rendimiento académico de 112 estudiantes y comparar con los resultados reales conseguidos terminado el curso. Se obtuvo una exactitud de las predicciones de casi 76% con tan solo pocas actividades académicas al inicio del curso, las cuales son frecuentemente registradas por los profesores facilitando que este tipo de estudio pueda ser replicado en diferentes cursos.

PALABRAS CLAVES: prevención, aprendizaje automático, Bayes ingenuo, k vecinos más cercanos, árbol de decisión.

TITLE: Prediction of academic performance using the first academic activities of university students and machine learning techniques.

AUTHORS:

1. PhD. Andrés Rico Páez.
2. Master. Nora Diana Gaytán Ramírez.

ABSTRACT: The main objective of this study is to design and evaluate academic performance prediction models using machine learning techniques and the first academic activities of university students. The first grades of academic activities of 260 university students were collected to train machine learning techniques to predict the academic performance of 112 students and compare with the real results achieved after the course. An accuracy of predictions of almost 76% was obtained with only a few academic activities at the beginning of the course, which are frequently recorded by teachers, making it easier for this type of study to be replicated in different courses.

KEY WORDS: prevention, machine learning, *Naïve Bayes*, *k* nearest neighbors, decision tree.

INTRODUCCIÓN.**Perspectiva teórica.**

Recientemente, ha aumentado la cantidad de información almacenada como resultado del desarrollo de aplicaciones tecnológicas tales como el internet, telefonía celular, dispositivos móviles, entre otras (Witten *et al.*, 2005). La información se genera para los objetivos particulares de la aplicación tecnológica; no obstante, existe cierta información escondida que puede ser útil; es decir, que tiene el potencial de brindar un cierto beneficio que se puede obtener mediante el análisis de dicha información. Una opción para este análisis son las técnicas de aprendizaje automático empleadas en áreas de negocio o empresariales (Han, 2012). En ambientes educativos, se ha comenzado a utilizar este tipo de técnicas debido al interés de encontrar información que pueda mejorar los procesos de enseñanza y de aprendizaje. De hecho, existe una cierta tendencia al uso de este tipo de herramientas en instituciones educativas (Romero y Ventura, 2010, 2012; Peña, 2014).

La predicción del rendimiento académico es una de las aplicaciones de mayor interés de las técnicas de aprendizaje automático debido a que posibilita identificar, de manera temprana, problemas académicos y realizar las medidas pertinentes (Cobo *et al.*, 2011; Márquez, Romero y Ventura, 2012; Xing *et al.*, 2015; La Red, Karanik *et al.*, 2015).

Gómez *et al.* (2011) y Gordillo *et al.* (2013) mencionan que el rendimiento académico depende de varios factores. Algunos de éstos son el comportamiento del estudiante, la presencia motivadora del profesor, entre otros (Escamilla y Heredia, 2019; Ramos y Roque, 2021); de esta manera, es posible predecir, con cierta incertidumbre, el rendimiento académico de estudiantes mediante los factores que interactúan con ellos. Shahiri *et al.* (2015) realizaron una revisión de los principales factores y técnicas de aprendizaje automático empleados para la predicción del rendimiento académico. Los autores concluyeron que las actividades académicas y el promedio actual son los más utilizados.

Antecedentes.

El aprendizaje automático se enfoca en el desarrollo de algoritmos y programas informáticos capaces de aprender un modelo a partir de datos, y está orientado hacia el resultado; es decir, requieren de un conjunto de datos de entrenamiento para crear los modelos de predicción. Una de las técnicas de aprendizaje automático es conocida como Bayes ingenuo. Es un algoritmo que utiliza fórmulas basadas en el teorema de Bayes para calcular probabilidades de los atributos de los registros de entrenamiento. Con estas probabilidades, se crea el modelo de predicción, de tal manera que combina dichas probabilidades para predecir el atributo de interés de un nuevo registro (Han, 2012).

Otra técnica de aprendizaje automático es k vecinos más cercanos, la cual predice el atributo de interés del registro de acuerdo con el valor del atributo que aparezca con mayor frecuencia entre los k vecinos más cercanos conforme a cierta métrica, generalmente, la distancia euclidiana (Hernández *et al.*, 2004); es decir, para cada registro a predecir su atributo se calcula la distancia con cada uno de los registros de entrenamiento y se seleccionan los k registros de entrenamiento más cercanos al

registro a predecir; finalmente, la predicción del registro será la que más se repita entre los k registros seleccionados. Una forma de seleccionar el valor de k es aquel que maximice la métrica de interés, comúnmente, la exactitud de la predicción en los datos de entrenamiento.

Una de las técnicas de aprendizaje automático más empleadas es la de árbol de decisión C4.5 desarrollada por Quinlan (1993). Para facilitar la comprensión, en este trabajo, se referirá a esta técnica solamente como árbol de decisión. Consiste en la construcción de un conjunto de condiciones estructuradas de forma jerárquica, de tal manera, que la decisión final se determina siguiendo las condiciones que se cumplen desde el origen del árbol hasta alguna de las hojas. Cada nodo del árbol tiene asociada una regla que sigue hacia uno u otro descendiente hasta llegar a un nodo final que indicará la predicción del registro.

Planteamiento del problema.

En la literatura revisada se ha identificado, que en México existen pocos trabajos que utilizan técnicas de aprendizaje automático para predecir el rendimiento académico como el presentado por Juárez *et al.* (2014); esto a pesar de que tengan el potencial de permitir el diseño de estrategias de prevención de reprobación de estudiantes en instituciones educativas.

Esta investigación se elaboró para responder la pregunta: ¿Cómo predecir el rendimiento académico de estudiantes mediante las primeras actividades académicas y técnicas de aprendizaje automático consideradas? ¿Cómo evaluar los modelos de predicción construidos?; por lo tanto, el propósito de este estudio es diseñar y evaluar modelos de predicción del rendimiento académico utilizando las primeras actividades académicas de estudiantes universitarios mediante técnicas de aprendizaje automático.

DESARROLLO.

Metodología.

La metodología utilizada consiste en emplear las calificaciones de las primeras actividades académicas de estudiantes para predecir su rendimiento académico al final de un curso como se muestra en la figura 1. De esta manera, el profesor y la institución educativa tienen la oportunidad de detectar a los estudiantes que pueden reprobado y tomar acciones al respecto.

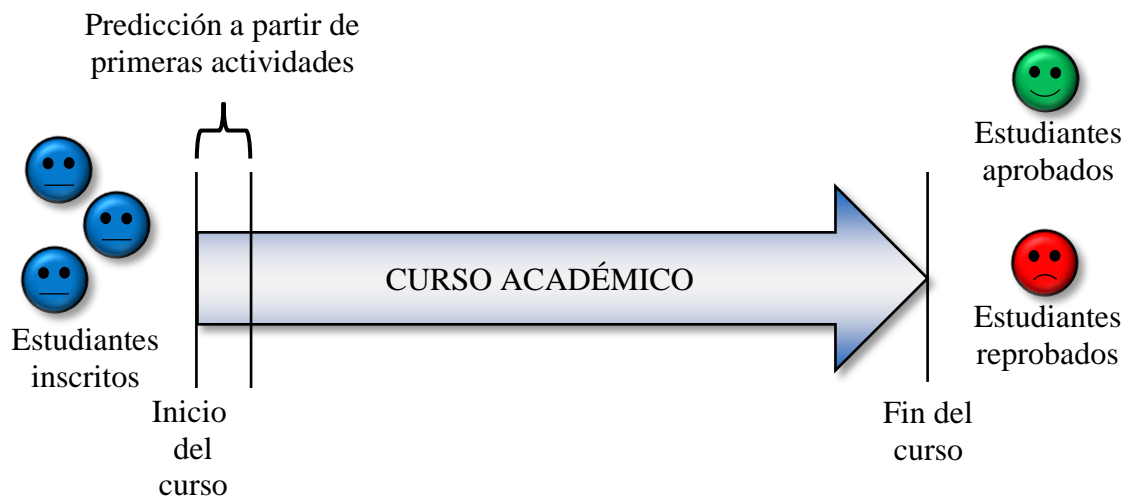


Figura 1. Metodología propuesta para predecir el rendimiento académico al final del curso.

Participantes.

En este trabajo se recabaron las calificaciones de las primeras 5 actividades académicas y la calificación final de un curso de matemáticas de una universidad de México. Las calificaciones de las actividades se simbolizan con los atributos act1, act2, act3, act4 y act5, y pueden tener los valores de Aprobada "A" (6.0-10.0); Reprobada "R" (0.0-5.9) y No Presentó "NP". La calificación final se representa con el atributo "aprueba" y puede tener los valores de "SÍ" o "NO". Con los datos recopilados se realizó una tabla con 260 registros de estudiantes, una muestra de estos datos se presenta en la tabla 1.

Tabla 1. Muestra de datos recopilados para el estudio.

| Estudiante | act1 | act2 | act3 | act4 | act5 | aprueba |
|------------|------|------|------|------|------|---------|
| 1 | R | A | R | A | A | SI |
| 2 | NP | NP | NP | NP | NP | NO |
| 3 | R | A | R | A | A | NO |
| 4 | NP | NP | R | A | A | SI |
| 5 | R | NP | R | A | A | SI |
| 6 | NP | NP | A | NP | A | SI |
| 7 | R | R | R | NP | A | SI |
| 8 | NP | NP | NP | NP | NP | NO |
| 9 | R | NP | A | A | NP | NO |
| 10 | R | NP | R | A | NP | SÍ |
| 11 | NP | NP | A | A | A | SÍ |
| 12 | R | A | NP | A | A | SÍ |
| 13 | NP | A | NP | R | NP | NO |
| 14 | NP | NP | NP | NP | NP | NO |
| 15 | R | A | A | A | A | NO |
| 16 | NP | NP | A | NP | NP | NO |
| 17 | R | NP | R | NP | NP | NO |
| 18 | R | A | A | A | A | SÍ |
| 19 | R | R | A | NP | A | NO |
| 20 | NP | A | A | R | NP | NO |

Para construir los modelos de predicción, se utilizaron las técnicas de aprendizaje automático Bayes ingenuo, k vecinos más cercanos, y árbol de decisión. Una vez construidos los modelos, se evaluaron mediante la exactitud de las predicciones, la cual representa la cantidad de predicciones correctamente predichas con respecto a la cantidad total de registros (Durairaj y Vijitha, 2014).

Las técnicas de aprendizaje automático permiten construir modelos de predicción empleando un conjunto de datos conocidos como datos de entrenamiento. En este trabajo se evalúan las técnicas de aprendizaje automático, primeramente, prediciendo valores de los datos de entrenamiento para estimar la exactitud con datos de entrenamiento, y posteriormente, prediciendo valores de datos diferentes a los de entrenamiento conocidos como datos de prueba y compararlo con los resultados reales obtenidos por los estudiantes para obtener la exactitud con datos de prueba. La construcción y evaluación de los modelos de predicción en los datos de entrenamiento y prueba se realizó con ayuda del software Weka (Witten *et al.*, 2005).

Evaluación con datos de entrenamiento.

La evaluación con datos de entrenamiento consiste en predecir valores del conjunto de datos de entrenamiento; es decir, con los datos con los que las técnicas de aprendizaje construyen los modelos; no obstante, al evaluar las técnicas de aprendizaje automático directamente en el conjunto de datos de entrenamiento podría favorecer a las técnicas que se ajustan más al conjunto de datos de entrenamiento. Una manera de disminuir este problema es mediante la validación cruzada, la cual consiste en dividir aleatoriamente los datos de entrenamiento en n particiones o grupos del mismo tamaño o similar.

Se utilizan $n-1$ grupos para construir el modelo con la técnica de aprendizaje automático y el grupo restante se utiliza para predecir sus valores para finalmente calcular la exactitud. Este proceso de repite n veces, dejando un grupo diferente para predecir sus valores y calcular la exactitud, esto se muestra en la figura 2.

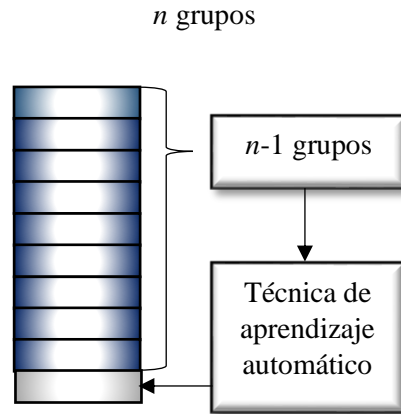


Figura 2. Validación cruzada.

Para el cálculo de la exactitud global se promedia las exactitudes obtenidas de las n particiones. En este trabajo se utiliza la validación cruzada con 10 particiones, debido a que es el valor más utilizado en la literatura (Valero *et al.*, 2010; Márquez *et al.*, 2012; Mueen *et al.*, 2016).

En esta sección se aplica la validación cruzada con las técnicas de aprendizaje automático Bayes ingenuo, k vecinos más cercanos y árbol de decisión con el propósito de estimar la exactitud de cada una.

En el caso de la técnica k vecinos más cercanos se requiere estimar el valor de k que consiga las mejores predicciones. Una manera de hacer esto, es calcular la exactitud de las predicciones con los datos de entrenamiento utilizando la validación cruzada con 10 particiones para distintos valores de k ; es decir, se calcula la exactitud para valores desde 1 hasta el número total de registros (1, 2, 3, ..., 260) y se selecciona el valor de k que de la mayor exactitud. En la figura 3 se presenta la gráfica de la exactitud de las predicciones obtenida con la validación cruzada para diferentes valores de k .

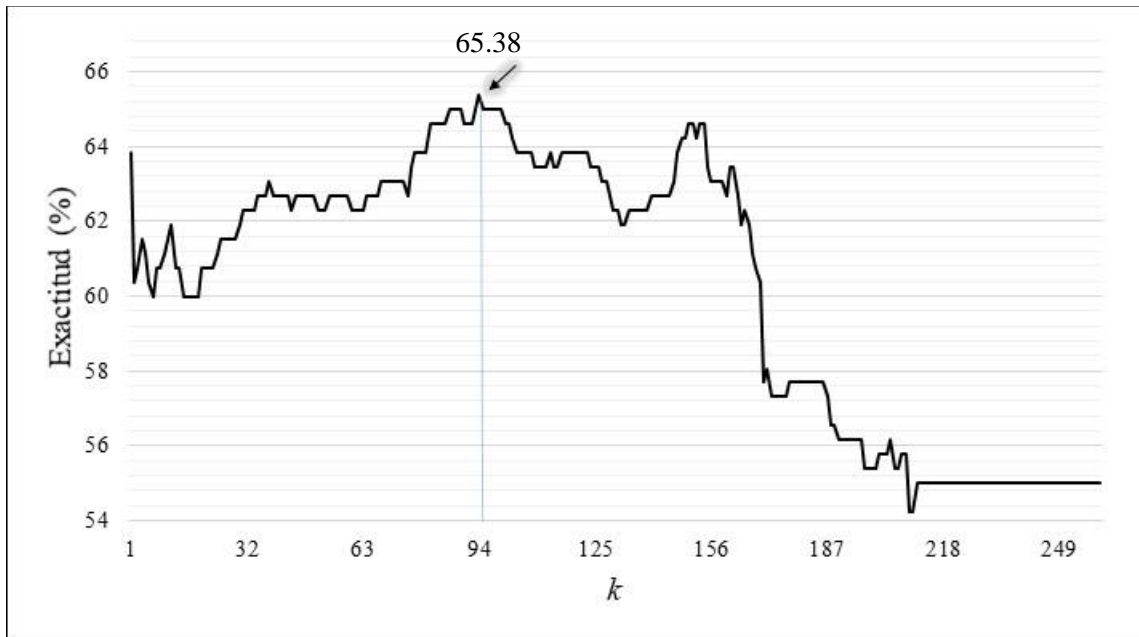


Figura 3. Exactitud con la técnica k vecinos más cercanos para diferentes valores de k .

De la gráfica anterior, se encuentra, que para el valor de $k = 94$ se obtiene el valor máximo de exactitud de 65.38%. Se observa que para valores pequeños de k (aproximadamente inferiores a 80) se obtiene una exactitud baja, debido a que no se tiene un número suficiente de registros cercanos que permitan tomar una decisión suficientemente confiable.

Para valores grandes de k (aproximadamente mayores a 210), el algoritmo considera demasiados registros y tiende a tomar decisiones en base a la cantidad total de registros con el valor del atributo mayoritario de los datos de entrenamiento. En este estudio, son 117 registros con el valor de “SÍ” en el atributo “aprueba” y 143 registros con el valor de “NO”; es decir, el valor “NO” es el valor del atributo “aprueba” mayoritario, por lo que la exactitud para valores de k , aproximadamente mayores a 210, tiende a ser $100\% * [143 / (117 + 143)] = 55\%$.

Una vez definido el valor de k se procede a aplicar las técnicas de aprendizaje automático al conjunto de datos de entrenamiento por medio de la validación cruzada con 10 particiones para calcular la exactitud de cada técnica como se muestra en la figura 4.

En la figura 4 se muestra que la exactitud con la técnica de árbol de decisión es superior a Bayes ingenuo y k vecinos más cercanos, las cuales presentan la misma exactitud en las predicciones.




Figura 4. Exactitud de las técnicas de aprendizaje automático con los datos de entrenamiento.

Evaluación con datos de prueba.

La evaluación con datos de entrenamiento mediante validación cruzada es una estimación del comportamiento que tendrá una técnica de aprendizaje con otros datos; sin embargo, para evaluar el comportamiento de una técnica con datos reales es necesario evaluarla directamente sobre esos datos. La evaluación con datos de prueba consiste en predecir valores de un conjunto de datos diferente al de entrenamiento llamado datos de prueba. Este tipo de evaluación se muestra en la figura 5. La exactitud se obtiene con la cantidad de registros de datos de prueba correctamente predichos entre el total de registros.




Figura 5. Evaluación con datos de prueba.

En esta sección se desarrollan modelos predictivos con las técnicas de aprendizaje automático Bayes ingenuo, k vecinos más cercanos y árbol de decisión para aplicarlos a datos de prueba. Los datos de entrenamiento son los registros de 260 estudiantes de cursos anteriores al de análisis. Los datos de prueba son los registros de 112 registros de estudiantes inscritos en el curso de interés. Una vez realizadas las predicciones de los datos de prueba se compararon con los resultados reales conseguidos por los 112 estudiantes al final del curso para calcular la exactitud de cada técnica como se muestra en la figura 6.

En la figura 6 se muestra que la exactitud de las predicciones es mayor con la técnica Bayes ingenuo, luego con k vecinos más cercanos, y finalmente, con la de árbol de decisión.




Figura 6. Exactitud de las técnicas de aprendizaje automático con los datos de prueba.

CONCLUSIONES.

En este estudio se presentó cómo utilizando las primeras actividades académicas de un curso se pueden obtener predicciones del rendimiento académico de un estudiante al final de un curso con cierto porcentaje de exactitud dependiendo del tipo de técnica de aprendizaje automático utilizada.

Cuando se evalúan las técnicas de aprendizaje automático con los datos de entrenamiento se observa que la exactitud con la técnica de árbol de decisión es un poco mayor a las demás (no mayor a 1%); es decir, que prácticamente las técnicas de aprendizaje automático empleadas ofrecen la misma exactitud al evaluarlas con los datos de entrenamiento mediante validación cruzada.

Cuando se evalúan las técnicas de aprendizaje automático con los datos de prueba, se observa que la exactitud con la técnica Bayes ingenuo es superior por aproximadamente 6% a la de la técnica k vecinos más cercanos, y esta a su vez, es superior a la de la técnica árbol de decisión por aproximadamente 10%. Estos valores difieren de los obtenidos evaluando con datos de entrenamiento, esto es más evidente, en el hecho de que la exactitud con la técnica de Bayes ingenuo obtenida con datos de prueba es superior en casi 10% a la obtenida con datos de entrenamiento. La exactitud con la k vecinos más cercanos evaluando con datos de prueba es mayor en casi 5% a la obtenida con datos de entrenamiento. La exactitud con árbol de decisión obtenida con datos de prueba es menor en aproximadamente 6% a la obtenida con datos de entrenamiento; de esta manera, es difícil seleccionar una técnica de aprendizaje automático, con los datos empleados, que se utilizará para predecir datos de prueba tan solo evaluando con datos de entrenamiento.

Juárez *et al.* (2014) utilizaron las técnicas Bayes ingenuo, k vecinos más cercanos, y árbol de decisión ID3. Participaron 104 estudiantes como datos de entrenamiento y 60 estudiantes como datos de prueba. Se realizó la evaluación sobre los datos de prueba obteniendo el valor más alto de exactitud de 80% para ambas técnicas k vecinos más cercanos y Bayes ingenuo; sin embargo, requirió alrededor de 40 atributos correspondientes a datos iniciales del curso como datos personales, de domicilio, entre otros.

A diferencia del artículo mencionado, en este trabajo participaron una mayor cantidad de estudiantes; además, se obtuvo la exactitud con datos de entrenamiento y con datos de prueba. Aunque la exactitud más alta obtenida fue 76% con datos de prueba y con la técnica Bayes ingenuo, se debe

tener en cuenta que solo se utilizaron 5 atributos correspondientes a actividades académicas, las cuales son más comunes de registrar por los profesores que otros datos personales del estudiante. Sharma y Vishwakarma (2017) utilizaron únicamente la técnica de aprendizaje automático árbol de decisión conocida como ID3 y 4 atributos correspondientes a actividades académicas a mediados y casi al final del curso. Se evaluó con 70 registros de entrenamiento por medio de validación cruzada y se obtuvo una exactitud de 90%, posteriormente, se utilizaron 50 registros de entrenamiento para predecir el rendimiento académico de 20 estudiantes; sin embargo, en este último experimento no se compararon las predicciones con los datos reales obtenidos por los estudiantes, así que no se obtuvo la exactitud de las predicciones con datos de prueba. A diferencia del artículo mencionado, en este trabajo participaron una mayor cantidad de estudiantes en el estudio y se evaluó con datos de prueba. Además, se predice el rendimiento académico con las primeras actividades académicas, las cuales permiten a los profesores tomar las medidas necesarias con tiempo en lugar de realizar predicciones con actividades a la mitad o casi al final del curso en donde el profesor tiene pocas oportunidades de realizar alguna acción para evitar la reprobación.

REFERENCIAS BIBLIOGRÁFICAS.

1. Cobo, A., Rocha, R. y Álvarez, Y. (2011). Selección de atributos predictivos del rendimiento académico de estudiantes en un modelo de B-Learning. *Revista Electrónica de Tecnología Educativa*, 37, 1-13. doi: 10.21556/edutec.2011.37.390
2. Durairaj, M. y Vijitha, C. (2014). Educational Data mining for Prediction of Student Performance Using Clustering Algorithms. *International Journal of Computer Science and Information Technologies*, 5(4), 5987-5991. Recuperado de: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.567.8824&rep=rep1&type=pdf>

3. Escamilla, M. y Heredia Y. (2019). Autodirección, habilidades de pensamiento y rendimiento académico en estudiantes normalistas. *Diálogos sobre educación. Temas actuales en investigación educativa*, 10(9). doi: 10.32870/dse.v0i19.492
4. Gómez, D., Oviedo, R. y Martínez, E. (2011). Factores que influyen en el rendimiento académico del estudiante universitario. *Educación y Humanidades*, 5(2), 90-97. Recuperado de: https://www.researchgate.net/publication/305335495_Factores_que_influyen_en_el_rendimiento_academico_del_estudiante_universitario
5. Gordillo, E., Martínez, J. y Valles, H. G. (2013). Rendimiento académico en escuelas de nivel medio superior. *IE Revista de Investigación Educativa de la REDIECH*, 4(6), 51 – 58. Recuperado de: https://www.rediech.org/ojs/2017/index.php/ie_rie_rediech/article/view/570
6. Han, J. (2012). *Data Mining: Concepts and Techniques*. Waltham, EUA: Morgan Kaufmann Publishers.
7. Hernández, J., Ramírez, M. y Ferri, C. (2004). *Introducción a la minería de datos*. Madrid, España: Pearson.
8. Juárez, A., Cortés, J. y Coronilla, U. (2014). Aplicación de la inteligencia artificial en la sistematización de procesos educativos. Caso: Sistema de detección de riesgo escolar en ESCOM. *Revista Iberoamericana de Producción Académica y Gestión Educativa*, 1(1), 140-163. Recuperado de: <https://pag.org.mx/index.php/PAG/article/view/92/140>
9. La Red, D., Karanik, M., Giovannini, M. y Pinto, N. (2015). Perfiles de Rendimiento Académico: Un Modelo basado en Minería de datos. *Campus Virtuales*, 4(1), 12-30. Recuperado de: <http://uajournals.com/ojs/index.php/campusvirtuales/article/view/66>
10. Márquez, C., Romero, C., y Ventura, S. (2012). Predicción del Fracaso Escolar mediante Técnicas de Minería de Datos. *IEEE-RITA*, 7(3), 109-117. Recuperado de <http://rita.det.uvigo.es/201208/uploads/IEEE-RITA.2012.V7.N3.A1.pdf>

11. Mueen, A., Zafar, B., y Manzoor U. (2016). Modeling and Predicting Students' Academic Performance Using Data Mining Techniques. *International Journal of Modern Education and Computer Science*, 11, 36-42. doi: 10.5815/ijmecs.2016.11.05
12. Peña, A. (2014). Review: Educational data mining: A survey and a data mining based analysis of recent works. *Expert Systems with Applications*, 41(4),1432-1462. doi: 10.1016/j.eswa.2013.08.042
13. Quinlan, J. (1993). *C4.5: Programs for machine learning*. San Francisco, E. U. A., Morgan Kaufmann.
14. Ramos, C. L. y Roque, R. V. (2021). La influencia docente y el rendimiento académico en estudiantes de una Universidad Pública Mexicana. *Revista Dilemas Contemporáneos: Educación, Política y Valores*, 8(7). Recuperado de: <https://www.dilemascontemporaneoseducacionpoliticayvalores.com/index.php/dilemas/article/view/2755/2777>
15. Romero, C., y Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 40(6), 601-618. doi: 10.1109/TSMCC.2010.2053532
16. Romero, C., y Ventura, S. (2012). *Data mining in education*. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3(1), 12-27. doi: 10.1002/widm.1075
17. Shahiri, A. M., Husain, W. y Rashid, N. (2015). A Review on Predicting Student's Performance using Data Mining Techniques. *Procedia Computer Science*, 72, 414-422. doi: 10.1016/j.procs.2015.12.157
18. Sharma, G. y Vishwakarma, S. K. (2017). Analysis and Prediction of Student's Academic Performance in University Courses. *International Journal of Computer Applications*, 160(4), 40-44. doi:10.5120/IJCA2017913045

19. Valero, S., Salvador, A., y García, M. (2010). Minería de datos: predicción de la deserción escolar mediante el algoritmo de árboles de decisión y el algoritmo de los k vecinos más cercanos. En M. E. Prieto, J. M. Doderó y D. O. Villegas (Eds.), *Lecture Notes in Computer Science: Vol. Kaambal. Recursos digitales para la educación y la cultura*. (pp. 33-39). Mérida, México. Recuperado de <http://www.utim.edu.mx/~svalero/docs/e1.pdf>
20. Witten, I., Frank, E. y Hall, M. (2005). *Data Mining: Practical Machine Learning Tools and Techniques*. Massachusetts, EUA: Morgan Kaufmann Publishers.
21. Xing, W., Guo, R., Petakovic, E., y Goggins, S. (2015). Participation-based student final performance prediction model through interpretable Genetic Programming: Integrating learning analytics, educational data mining and theory. *Computers in Human Behavior*, 47, 168-181. doi: 10.1016/j.chb.2014.09.034

DATOS DE LOS AUTORES.

1. **Andrés Rico Páez.** Doctor en Tecnología Avanzada y Profesor Titular en la Escuela Superior de Ingeniería Mecánica y Eléctrica unidad Zacatenco del Instituto Politécnico Nacional. México. Correo electrónico: aricop.ipn@gmail.com
2. **Nora Diana Gaytán Ramírez.** Maestra en Tecnología Avanzada. Estudiante de Doctorado en Tecnología Avanzada en el Centro de Investigación de Ciencia Aplicada y Tecnología Avanzada, Unidad Legaria del Instituto Politécnico Nacional. México. Correo electrónico: nora_diana@hotmail.com

RECIBIDO: 4 de enero del 2022.

APROBADO: 15 de marzo del 2022.