

Sistema de Inteligencia Artificial para la Predicción del Rendimiento Académico Universitario: Comparativa de Metodologías

Artificial Intelligence System for Predicting University Academic Performance: A Comparative Study of Methodologies

Chuquizala Erazo Diana Carolina¹  · Cabascango Cáceres Damian Esteban² 
Reyes Wagnio Manuel³  · Rumbaut Rangel Dayron⁴ 

INFORMACIÓN DEL ARTÍCULO

Fecha de recepción: 21 de mayo de 2026.
Fecha de aceptación: 18 de junio de 2026.
Fecha de publicación: 11 de septiembre de 2026.

¹Chuquizala Erazo Diana Carolina
<https://orcid.org/0009-0002-0915-3612>
Universidad Bolivariana del Ecuador
dcchuquizalae@ube.edu.ec

²Cabascango Cáceres Damian Esteban
<https://orcid.org/0009-0004-1531-6857>
Universidad Bolivariana del Ecuador
damian.cabascango@epoch.edu.ec

³Reyes Wagnio Manuel
<https://orcid.org/0000-0002-3102-0034>
Universidad Bolivariana del Ecuador;
Universidad de Guayaquil
mfreyesw@ube.edu.ec

⁴Rumbaut Rangel Dayron
<https://orcid.org/0009-0001-9087-0979>
Universidad Bolivariana del Ecuador
drumbautr@ube.edu.ec

RESUMEN

La educación superior enfrenta limitaciones en el seguimiento del rendimiento académico debido al predominio de metodologías tradicionales, lo que ha impulsado la incorporación de la inteligencia artificial (IA) como herramienta para optimizar los procesos educativos. En este contexto, la presente investigación tuvo como propósito diseñar y evaluar un sistema basado en IA para predecir el rendimiento académico de estudiantes universitarios mediante el análisis de datos educativos y la comparación entre metodologías tradicionales y estrategias apoyadas en IA. Se desarrolló un estudio cuantitativo con diseño experimental en una muestra de 80 estudiantes distribuidos en un grupo control y un grupo experimental. La recolección de datos se realizó mediante evaluaciones académicas, formularios digitales y registros de actividad, mientras que el procesamiento se efectuó con algoritmos de aprendizaje automático como regresión logística, árboles de decisión y redes neuronales. Los resultados evidenciaron un mayor rendimiento académico en el grupo experimental ($M=8,3$) frente al grupo control ($M=7,2$), con diferencias estadísticamente significativas ($p < 0,001$), además de mayores niveles de participación y uso de recursos educativos. El modelo predictivo alcanzó una exactitud del 85 %, demostrando una adecuada capacidad para anticipar el desempeño estudiantil. Se concluye que la IA constituye una herramienta clave para fortalecer el rendimiento académico y apoyar la toma de decisiones pedagógicas basadas en datos en el contexto de la educación superior.

Palabras clave: Inteligencia Artificial, rendimiento académico, educación superior, modelos predictivos, aprendizaje automático



ABSTRACT

Higher education faces limitations in monitoring academic performance due to the predominance of traditional methodologies, which has encouraged the incorporation of artificial intelligence (AI) as a tool to optimize educational processes. In this context, the present study aimed to design and evaluate an AI-based system to predict university students' academic performance through the analysis of educational data and the comparison between traditional methodologies and AI-supported strategies. A quantitative study with an experimental design was conducted on a sample of 80 students divided into a control group and an experimental group. Data collection was carried out through academic assessments, digital forms, and activity records, while data processing was performed using machine learning algorithms such as logistic regression, decision trees, and neural networks. The results showed higher academic performance in the experimental group ($M=8.3$) compared to the control group ($M=7.2$), with statistically significant differences ($p < 0.001$), as well as higher levels of participation and use of educational resources. The predictive model achieved an accuracy of 85 %, demonstrating an adequate capacity to anticipate student performance. It is concluded that AI represents a key tool for improving academic performance and supporting data-driven pedagogical decision-making in higher education.

Keywords: artificial intelligence, academic performance, higher education, predictive models, machine learning

INTRODUCCIÓN

En los últimos años, la educación superior ha experimentado transformaciones significativas impulsadas por el avance de las tecnologías digitales, lo que ha generado cambios en los procesos de enseñanza y aprendizaje (Sweeney et al., 2016). En este contexto, la incorporación de herramientas tecnológicas ha permitido el desarrollo de estrategias pedagógicas orientadas a mejorar la calidad educativa, optimizar el acceso al conocimiento y fortalecer la interacción entre docentes y estudiantes. La inteligencia artificial (IA) actualmente se posiciona como una innovación con gran relevancia para el ámbito educativo, gracias a su potencial para la transformación de procesos tanto de enseñanza como de aprendizaje (UNESCO, 2023; OECD, 2019).

La IA permite el procesamiento de grandes volúmenes de información, identificar patrones en datos y generar modelos predictivos para el contexto educativo, por lo que se ha posicionado con un papel muy relevante en cuanto a la educación superior. Algunos estudios señalan que utilizar la IA permite facilitar el análisis del comportamiento académico de los estudiantes, además de contribuir a la toma de decisiones pedagógica basadas en datos. (Holmes et al., 2019; Zawacki-Richter et al., 2019; Baker & Inventado, 2014). La implementación de este tipo de sistemas resulta beneficioso al favorecer la personalización del aprendizaje, ya que permite adaptar los contenidos a las necesidades de cada uno de los estudiantes (Luckin et al., 2016; Hellas et al., 2018; Siemens & Baker, 2012).

A pesar de esto, en la mayoría de las instituciones de educación superior todavía prevalecen las metodologías tradicionales de enseñanza, por lo que se limita el seguimiento continuo del aprendizaje, además de dificultar la identificación temprana de posibles dificultades académicas.

Ifenthaler y Schumacher (2016) indican que el integrar tecnologías que se basen en el uso de IA puede contribuir a superar estas limitaciones, gracias al análisis de datos educativos y generación de información relevante que permita mejorar el proceso formativo.

El uso de los modelos predictivos que se basen en IA llega ser catalogados como una alternativa innovadora que permite comprender de mejor manera el rendimiento académico universitario (Waheed et al., 2019). Papamitsiou y Economides (2014) indican que este tipo de modelos también se anticipan a resultados académicos, lo que facilita la implementación de estrategias pedagógicas oportunas. A nivel teórico, la incorporación de estos modelos se sustenta en el cognitivismo, lo cual explica cómo es que los estudiantes procesan y organizan información, además de, en el conectivismo, ya que resalta la importancia de las redes y tecnología para la construcción de conocimiento gracias al uso de entornos digitales (Boettcher & Conrad, 2021; Siemens, 2005; Biggs et al., 2022).

Bajo este contexto, la presente investigación tiene como objetivo desarrollar un modelo predictivo que se base en el uso de inteligencia artificial para analizar el rendimiento académico universitario y comparar su efectividad frente a las metodologías de enseñanza tradicionales.

METODOLOGÍA

Enfoque y diseño de investigación

La presente investigación se desarrolló bajo un enfoque de tipo cuantitativo con un diseño experimental, mismo que se orientó a analizar el rendimiento académico de estudiantes universitarios gracias a la comparación del uso de metodología tradicionales y uso de estrategias educativas basadas en el uso de IA. Estructurándose en dos grupos de estudio: un grupo control, mismo al que se le aplicó una metodología tradicional basada en clases expositivas y evaluación convencional; y un grupo experimental, en el cual se implementaron estrategias apoyadas en inteligencia artificial, incluyendo el uso de herramientas digitales interactivas, sistemas de analítica del aprendizaje y mecanismos de retroalimentación automatizada y personalizada, con el propósito de fortalecer el seguimiento continuo del estudiante y optimizar su proceso de aprendizaje.

Población y muestra

La población estuvo conformada por estudiantes universitarios de primer nivel de la carrera de Administración de Empresas, pertenecientes la Escuela Superior Politécnica de Chimborazo en Ecuador. Se seleccionó una muestra de 80 estudiantes mediante muestreo no probabilístico por conveniencia, distribuidos equitativamente en dos grupos de 40 estudiantes cada uno.

Los criterios de inclusión consideraron estudiantes que tengan una matrícula activa, asistencia regular, acceso a dispositivos digitales y consentimiento para la participación en el estudio.

Variables de investigación

La variable dependiente del estudio fue el rendimiento académico, mismo que se midió gracias a la calificación inicial y final. Como variables independientes se tuvieron la metodología de enseñanza, definida según el tipo de estrategia aplicada, la participación académica, misma que se evaluó mediante el número de actividades realizadas, y el uso de recursos educativos que se midió por la frecuencia de acceso a la plataforma digital.

Procedimiento metodológico

La presente investigación se desarrolló en cuatro fases secuenciales: (1) Diagnóstico, con evaluaciones iniciales para determinar el nivel de conocimiento de

los estudiantes; (2) Intervención, implementación de las metodologías correspondientes a cada grupo; (3) Recolección de datos, mediante evaluaciones, formularios digitales y registros de actividad; y (4) Análisis de datos, procesamiento con herramientas de IA en Google Colab y el software estadístico Rstudio, permitiendo el procesamiento de la información y la aplicación de pruebas estadísticas para determinar la significancia de los datos.

Modelos de aprendizaje automático y métricas

Para el análisis se emplearon algoritmos de aprendizaje automático, tales como regresión logística, árboles de decisión y redes neuronales, para identificar patrones y poder predecir el rendimiento académico de los estudiantes.

El desempeño del modelo se evaluó gracias a métricas estándar de calificación, como accuracy, misma que representa la proporción de predicciones correctas; precisión, que mide la exactitud en la predicción de la clase positiva; recall, que indica la capacidad del modelo para identificar los casos positivos; y F1-score, es la medida armónica de precision y recall.

Todos los participantes firmaron un consentimiento informado antes de iniciar el estudio, los datos fueron anonimizados para garantizar la confidencialidad y el uso responsable de la información.

Consideraciones éticas

La presente investigación fue desarrollada en cumplimiento de los lineamientos éticos de la Escuela Superior Politécnica de Chimborazo (ESPOCH) para estudios con seres humanos. El estudio fue avalado por la instancia académica correspondiente, garantizando el respeto a la normativa institucional y a los principios éticos de la investigación educativa.

Todos los participantes fueron informados sobre los objetivos, procedimientos y alcance del estudio, y otorgaron su consentimiento informado de manera voluntaria antes de su participación. Se garantizó en todo momento la confidencialidad, anonimato y protección de los datos personales.

El tratamiento de la información se realizó bajo principios de responsabilidad, integridad académica y uso ético de los datos, asegurando su utilización exclusivamente con fines científicos.

Chuquizala Erazo Diana Carolina · Cabascango Cáceres Damian Esteban · Reyes Wagnio Manuel · Rumbaut Rangel Dayron

ANÁLISIS DE RESULTADOS

Los resultados se presentan en función de dos componentes: el análisis del rendimiento académico y la evaluación del modelo predictivo que se basó en IA.


Rendimiento académico de los grupos de estudio

Tabla 1
Comparación del rendimiento académico entre grupos

Grupo	Promedio inicial	Promedio final	Mejora (%)
Grupo control (tradicional)	6,5	7,2	10,7 %
Grupo experimental (IA)	6,4	8,3	29,7 %

En la fase diagnóstica, los dos grupos presentaron niveles similares en cuanto a conocimiento. Pero tras la intervención, el grupo experimental evidenció una mejora del 29,7 % frente al 10,7 % del grupo control, como se observa en la Tabla 1.

Figura 1
Comparación del rendimiento académico entre el grupo control y el grupo experimental



Nota. Elaboración propia con base en los resultados del estudio.

La Figura 1 muestra la comparación del rendimiento académico final entre el grupo control y el experimental. Se observa que el grupo experimental obtuvo un promedio superior al del grupo control, lo que evidencia la existencia de un mejor desempeño académico en los estudiantes que participaron en la intervención basada en inteligencia artificial. El grupo control obtuvo un promedio final de 7,2, mientras que el experimental de 8,3, lo que representa una diferencia favorable de 1,1 puntos a favor del grupo experimental.


Para determinar si esta diferencia fue estadísticamente significativa, se aplicó la prueba t de Student para muestras independientes. Los resultados indican diferencias estadísticamente significativas entre ambos grupos, $t(74,73) = -11,29$, $p < 0,001$. El intervalo de confianza es del 95 % para la diferencia de medias fue $[-1,29; -0,91]$, lo que confirma que la mejora observada no se debe al azar.

Además, se calculó el tamaño del efecto mediante el coeficiente d de Cohen, obteniendo un valor de 2,52, lo que indica un efecto grande. En conjunto, estos resultados evidencian que la intervención apoyada en IA tuvo un impacto significativo y relevante en cuanto al rendimiento académico de los estudiantes.

Participación y uso de recursos educativos

Los indicadores de interacción académica que se muestran en la Figura 2 evidencian diferencias claras: los resultados evidencian una superioridad del grupo experimental en todos los indicadores analizados, destacando especialmente el uso de recursos digitales y la participación académica (88 % vs. 65 %), mayor uso de recursos digitales (92 % vs. 60 %) y mayor participación general (90 % vs. 70 %).

Figura 2
Comparación de actividades, uso de recursos y participación entre el grupo control y el grupo experimental



Nota. Elaboración propia con base en los resultados del estudio.

Resultados del modelo predictivo

Tabla 2
Métricas del modelo predictivo

Modelo	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Regresión logística	82	80	79	79
Árbol de decisión	83	81	80	80
Redes neuronales	85	83	82	82

El desempeño de los modelos predictivos se evaluó mediante métricas estándar de clasificación. Como se presenta en la Tabla 2, el modelo de redes neuronales obtuvo el mejor rendimiento, con una accuracy del 85 %, y el árbol de decisión, con 83 %, y la regresión logística, con 82 %. Estos resultados evidencian que existe mayor capacidad predictiva del modelo basado en redes neuronales.

Variables con mayor influencia en la predicción

Las variables con mayor influencia en cuanto a la predicción del rendimiento académico fueron las evaluaciones previas y la participación académica, mismas que se encuentran seguidas del uso de recursos educativos y el tiempo dedicado al estudio. Por lo tanto, estos resultados dejan clara la importancia de los factores conductuales del desempeño de los estudiantes.

Discusión

Los resultados evidencian que el diseño de un sistema basado en IA para la predicción del rendimiento académico constituye una alternativa pertinente en el contexto de la educación superior contemporánea. El mejor desempeño del grupo experimental sugiere que estas herramientas aportan valor tanto tecnológico como pedagógico, al favorecer procesos de aprendizaje más dinámicos y orientados al seguimiento continuo del estudiante. Este hallazgo es coherente con lo planteado por la UNESCO (2023), que sostiene que la IA tiene el potencial de transformar los procesos educativos al facilitar el acceso al conocimiento y mejorar la calidad del aprendizaje.

De esta manera, Chen et al. (2020) destacan que la inteligencia artificial aplicada a la educación permite optimizar los procesos de enseñanza mediante sistemas predictivos y análisis de datos orientados a mejorar el desempeño estudiantil.

Khosravi et al. (2022), señala que los sistemas basados en inteligencia artificial y analítica del aprendizaje permiten identificar tempranamente factores asociados al bajo rendimiento académico, favoreciendo intervenciones educativas más oportunas y personalizadas.

La diferencia entre el grupo control y el grupo experimental no debe interpretarse únicamente como una ventaja técnica de las herramientas digitales, sino como una transformación en la manera de acompañar el aprendizaje. Mientras las metodologías tradicionales se centran en la transmisión de contenidos y la evaluación final, las estrategias apoyadas en IA incorporan procesos de retroalimentación continua y seguimiento individualizado. La OCDE (2021) destaca que el uso de sistemas basados en datos en educación favorece la personalización del aprendizaje y mejora la capacidad de los docentes para adaptar sus estrategias pedagógicas.

La capacidad del modelo de IA para predecir el rendimiento académico con un accuracy del 85 % es significativa, pues demuestra que los datos generados durante el proceso educativo —calificaciones, participación y uso de recursos— pueden construir modelos predictivos confiables. La OCDE (2021) señala que el uso de IA en educación permite aprovechar los datos educativos para mejorar la toma de decisiones, siempre que se utilicen de manera responsable y contextualizada.

Las variables relacionadas con la participación académica, el uso de recursos educativos y el tiempo de dedicación al estudio tienen una influencia significativa en el rendimiento. Esto refuerza la idea de que el desempeño estudiantil es un fenómeno complejo que trasciende las calificaciones. La UNESCO (2023) señala que el análisis de datos educativos permite comprender mejor los procesos de aprendizaje y diseñar estrategias de apoyo más efectivas. Sin embargo, el uso de estas tecnologías debe estar acompañado de un enfoque crítico y ético que garantice la protección de los datos de los estudiantes (OCDE, 2021).

Los resultados confirman que las estrategias apoyadas en IA pueden generar mejores resultados que las metodologías tradicionales, aunque este beneficio depende de su adecuada articulación con enfoques pedagógicos pertinentes. La IA debe entenderse como una herramienta de apoyo que fortalece el proceso educativo y requiere de la mediación docente para ser efectiva, y no como un sustituto del rol del profesor.

CONCLUSIONES

El desarrollo de un sistema que se basa en inteligencia artificial para la predicción del rendimiento académico ha demostrado ser una estrategia pertinente en el contexto de la educación superior, y de esta manera se evidencian mejoras en cuanto al desempeño estudiantil sobre todo frente al uso de metodologías tradicionales. Por ello se confirmó que el uso de modelos predictivos permite analizar de manera integral el comportamiento académico, permitiendo incorporar variables como la participación, interacción y uso de recursos educativos.

Además, las estrategias educativas que se apoyan en la inteligencia artificial favorecen la personalización de aprendizaje y el seguimiento del estudiante, por lo que se ayuda a la toma adecuada de decisiones pedagógicas mejor informadas. Sin embargo, su efectividad depende de la adecuada integración con enfoques pedagógicos, además del acompañamiento docente.

Existe una limitante en cuanto al estudio, ya que el tamaño de la muestra y su aplicación en un contexto educativo único puede restringir la generalización de resultados. Para investigaciones futuras se recomienda aplicar la población estudiada e incorporar modelos predictivos más robustos, que permitan el fortalecimiento y la precisión y aplicabilidad de los sistemas basados en inteligencia artificial para la educación.

Finalmente, la implementación de este tipo de tecnologías se debe realizar bajo principios éticos que garantice siempre la protección de datos y el uso responsable de la información, para de esta manera promover el equilibrio entre la innovación tecnológica y la práctica educacional.

Financiamiento: La presente investigación no recibió financiamiento externo y fue desarrollada con recursos propios de los autores.

Declaración de conflicto de intereses: Los autores declaran no tener ningún conflicto de intereses respecto a la publicación de este artículo.

REFERENCIAS

- Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In J. A. Larusson & B. White (Eds.), *Learning analytics: From research to practice* (pp. 61–75). Springer.
- Biggs, J., Tang, C. & Kennedy, G. (2022). *Teaching for quality learning at university* (5th ed.). McGraw-Hill.
- Boettcher, J. V., & Conrad, R. M. (2021). *The Online Teaching Survival Guide: Simple and Practical Pedagogical Tips* (3rd ed.). Jossey-Bass.
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- Hellas, A., Ihantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., Knutas, A., Leinonen, J., Messom, C., & Liao, S. N. (2018). *Predicting academic performance: A systematic literature review*. En *Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education (ITiCSE '18 Companion)* (pp. 175–199). Association for Computing Machinery. <https://doi.org/10.1145/3293881.3295783>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.
- Ifenthaler, D., & Schumacher, C. (2016). Student perceptions of privacy principles for learning analytics. *Educational Technology Research and Development*, 69(2), 821–839. <https://doi.org/10.1007/s11423-016-9477-y>
- Khosravi, H., Buckingham Shum, S., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). *Explainable artificial intelligence in education*. *Computers and Education: Artificial Intelligence*, 3, 100074. <https://doi.org/10.1016/j.caeai.2022.100074>
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson.
- OECD. (2019). *Artificial intelligence in society*. OECD Publishing. <https://doi.org/10.1787/cedfee77-en>
- Papamitsiou, Z., & Economides, A. A. (2014). Learning analytics and educational data mining in practice: A systematic literature review. *Educational Technology & Society*, 23(2), 1–13.
- Siemens, G. (2005). Connectivism: A learning theory for the digital age. *International Journal of Instructional Technology and Distance Learning*, 2(1), 3–10.
- Siemens, G., & Baker, R. (2012). Learning analytics and educational data mining. In R. K. Sawyer (Ed.), *The Cambridge handbook of the learning sciences* (3rd ed.). Cambridge University Press.
- Sweeney, M., Lester, J., & Rangwala, H. (2016). Next-term student performance prediction. *Journal of Educational Data Mining*, 14(1), 1–25. <https://doi.org/10.5281/zenodo.3554603>
- Waheed, H., Hassan, S. U., Aljohani, N. R., Hardman, J., & Nawaz, R. (2019). Predicting academic performance of students from VLE big data using deep learning models. *Computers in Human Behavior*, 104, 106189. <https://doi.org/10.1016/j.chb.2019.106189>