

Predicción del bajo rendimiento académico mediante técnicas de minería de datos educativos en instituciones fiscales

Prediction of Low Academic Performance Using Educational Data Mining Techniques in Public Educational Institutions

Lic. Castro Tomala Hector Valentin

E.E.B. Enrique Camilo
hector.castro@educacion.gob.ec
<https://orcid.org/0009-0003-3933-1210>
Guayas – Ecuador

MSc. Balla Chacaguasay Susana

Cacique Tumbala
susana.balla@docentes.educacion.gob.ec
<https://orcid.org/0009-0003-7587-6242>
Guayas – Ecuador

MSc. Mateo Eugenio Gissela Paola

Cacique Tumbala
gissela.mateo@educacion.gob.ec
<https://orcid.org/0009-0005-0241-9950>
Guayas – Ecuador

MSc. Yagual Flores Giancarlo Mikhail

Polibio Jaramillo
giancarlo.yagual@educacion.gob.ec
<https://orcid.org/0009-0007-0658-0607>
Guayas – Ecuador

Formato de citación APA

Castro, H., Balla, S., Mateo, G. & Yagual, G. (2026). Predicción del bajo rendimiento académico mediante técnicas de minería de datos educativos en instituciones fiscales. Revista REG, Vol. 5 (Nº. 3), p. 6081 – 6097.

CONOCIMIENTOS SIN FRONTERAS

Vol. 5 (Nº. 3). Julio - septiembre 2026.

ISSN: 3073-1259

Fecha de recepción: 09-09-2026

Fecha de aceptación :12-09-2026

Fecha de publicación:30-09-2026



RESUMEN

El bajo rendimiento académico constituye una problemática recurrente dentro de los sistemas educativos, debido a su relación con dificultades de aprendizaje, riesgo de repitencia, abandono escolar y limitadas oportunidades de desarrollo académico. La identificación temprana de estudiantes con dificultades permite implementar estrategias de apoyo oportunas y fortalecer la gestión educativa basada en evidencia. En este contexto, la minería de datos educativos surge como una herramienta innovadora capaz de analizar grandes volúmenes de información académica para identificar patrones asociados al desempeño estudiantil. El presente artículo tiene como objetivo desarrollar un modelo predictivo basado en técnicas de minería de datos educativos para identificar estudiantes con riesgo de bajo rendimiento académico en instituciones fiscales. La investigación se desarrolló mediante un enfoque mixto, combinando análisis documental sobre minería de datos aplicada a educación y recopilación de información mediante instrumentos dirigidos a docentes y directivos. Los resultados evidencian que las principales variables relacionadas con el bajo rendimiento académico corresponden al historial de calificaciones, nivel de asistencia, cumplimiento de tareas, participación en actividades educativas y factores familiares. Asimismo, se determina que técnicas como árboles de decisión, regresión logística y algoritmos de clasificación permiten generar modelos capaces de anticipar dificultades académicas y apoyar la toma de decisiones institucionales. Se concluye que la minería de datos educativos representa una estrategia efectiva para fortalecer los procesos de seguimiento académico y prevención del bajo rendimiento, siempre que sea aplicada bajo criterios éticos, garantizando la protección de datos y la participación activa del docente en la interpretación de resultados.

PALABRAS CLAVE: minería de datos educativos, rendimiento académico, predicción educativa, inteligencia artificial, instituciones fiscales.

ABSTRACT

Low academic performance is a recurring problem within educational systems due to its relationship with learning difficulties, grade repetition, school dropout risk, and limited academic opportunities. Early identification of students with difficulties allows the implementation of timely support strategies and strengthens evidence-based educational management. In this context, educational data mining emerges as an innovative tool capable of analyzing large volumes of academic information to identify patterns associated with student performance. This article aims to develop a predictive model based on educational data mining techniques to identify students at risk of low academic performance in public educational institutions. The research followed a mixed-method approach, combining documentary analysis of educational data mining and information collected through instruments applied to teachers and administrators. The results show that the main variables associated with low academic performance are previous grades, attendance levels, assignment completion, participation in educational activities, and family factors. Likewise, classification techniques such as decision trees, logistic regression, and machine learning algorithms allow the development of predictive models capable of anticipating academic difficulties and supporting institutional decision-making. It is concluded that educational data mining represents an effective strategy to strengthen academic monitoring and prevent low performance, provided that it is applied under ethical criteria, ensuring data protection and active teacher participation in interpreting results.

KEYWORDS: educational data mining, academic performance, educational prediction, artificial intelligence, public institutions.

INTRODUCCIÓN

El rendimiento académico constituye uno de los principales indicadores utilizados para evaluar la calidad de los procesos educativos, debido a que refleja el nivel de logro alcanzado por los estudiantes durante su trayectoria escolar. Sin embargo, el bajo rendimiento académico representa una problemática compleja influenciada por múltiples factores académicos, personales, familiares e institucionales, lo que dificulta su identificación temprana mediante métodos tradicionales de evaluación.

En las instituciones educativas fiscales, la detección oportuna de estudiantes con dificultades académicas representa un desafío permanente debido al número elevado de estudiantes, diversidad de contextos sociales y limitaciones en los procesos sistemáticos de seguimiento individualizado. Generalmente, las acciones de intervención se desarrollan cuando los problemas de aprendizaje ya se encuentran establecidos, reduciendo las posibilidades de aplicar estrategias preventivas efectivas.

En este escenario, la incorporación de herramientas tecnológicas basadas en análisis de datos representa una oportunidad para transformar la gestión educativa. La minería de datos educativos (Educational Data Mining, EDM) se ha consolidado como un campo interdisciplinario que combina educación, estadística, inteligencia artificial y ciencias computacionales con la finalidad de descubrir patrones significativos dentro de los datos generados en los procesos de enseñanza-aprendizaje.

Según Romero y Ventura (2021), la minería de datos educativos permite analizar información académica para comprender el comportamiento de los estudiantes, identificar factores asociados al rendimiento y generar modelos predictivos que apoyen la toma de decisiones educativas.

Los sistemas educativos generan diariamente grandes cantidades de información relacionada con calificaciones, asistencia, participación, evaluaciones, interacción digital y antecedentes académicos. Estos datos, cuando son analizados mediante técnicas computacionales, pueden convertirse en herramientas estratégicas para anticipar dificultades y diseñar acciones de acompañamiento personalizado.

Las técnicas de minería de datos más utilizadas en educación incluyen:

- Árboles de decisión.
- Redes neuronales artificiales.
- Algoritmos de clasificación.
- Regresión logística.
- Máquinas de soporte vectorial.
- Agrupamiento de datos.

Estas técnicas permiten identificar relaciones entre variables académicas y establecer modelos capaces de predecir estudiantes con mayor probabilidad de presentar bajo rendimiento.

De acuerdo con Baker y Inventado (2021), la minería de datos educativos permite superar los análisis tradicionales basados únicamente en resultados finales, proporcionando información dinámica sobre los procesos de aprendizaje y comportamiento estudiantil.

La predicción del rendimiento académico no busca reemplazar el criterio profesional del docente, sino proporcionar información complementaria para fortalecer la toma de decisiones pedagógicas. Los resultados generados por los modelos predictivos deben interpretarse considerando el contexto individual del estudiante y evitando cualquier tipo de etiquetamiento académico.

En Ecuador, las instituciones fiscales enfrentan desafíos relacionados con rendimiento académico, permanencia escolar y atención a estudiantes con diferentes necesidades educativas. La implementación de modelos basados en minería de datos podría contribuir al fortalecimiento de los sistemas de seguimiento institucional y permitir intervenciones tempranas.

El Ministerio de Educación del Ecuador (2022) destaca la importancia de fortalecer la innovación educativa mediante el uso estratégico de tecnologías digitales y sistemas de información que permitan mejorar los procesos de gestión y acompañamiento educativo.

Sin embargo, la aplicación de minería de datos educativos requiere superar desafíos relacionados con disponibilidad de información estructurada, capacitación docente, infraestructura tecnológica y protección de datos personales.

Por ello, la presente investigación tiene como objetivo desarrollar un modelo predictivo basado en técnicas de minería de datos educativos para identificar estudiantes con riesgo de bajo rendimiento académico en instituciones fiscales, determinando las variables más influyentes y estableciendo una estrategia de apoyo para la toma de decisiones educativas.

MÉTODOS MATERIALES

La presente investigación se desarrolló bajo un enfoque mixto, debido a que integra métodos cuantitativos y cualitativos con el propósito de analizar los factores asociados al bajo rendimiento académico y diseñar un modelo predictivo basado en técnicas de minería de datos educativos para instituciones fiscales.

El componente cuantitativo permitió recopilar y analizar información relacionada con variables académicas y contextuales de los estudiantes, tales como calificaciones, asistencia, cumplimiento de actividades, participación escolar y factores familiares asociados al desempeño académico.

El componente cualitativo permitió interpretar las percepciones de docentes y directivos respecto al seguimiento estudiantil, dificultades para identificar oportunamente problemas de rendimiento y la posibilidad de incorporar herramientas tecnológicas basadas en análisis de datos para fortalecer la gestión académica.

La investigación presentó un diseño no experimental, debido a que las variables fueron observadas dentro de su contexto natural sin manipulación directa. Asimismo, tuvo un alcance descriptivo-propositivo, ya que permitió identificar los factores relacionados con el bajo rendimiento académico y posteriormente plantear un modelo predictivo mediante técnicas de minería de datos educativos.

ANÁLISIS DE RESULTADOS

Los resultados obtenidos permitieron identificar los principales factores relacionados con el bajo rendimiento académico y analizar la pertinencia de aplicar técnicas de minería de datos educativos como estrategia para la detección temprana de estudiantes con dificultades académicas en instituciones fiscales.

La información fue recopilada mediante una encuesta aplicada a 25 participantes (20 docentes y 5 directivos), considerando dimensiones relacionadas con historial académico, asistencia escolar, cumplimiento de actividades, factores familiares, gestión institucional y percepción sobre la aplicación de minería de datos educativos.

Los datos fueron procesados mediante estadística descriptiva utilizando frecuencias y porcentajes, permitiendo establecer las variables con mayor influencia en la predicción del rendimiento académico.

Tabla 1.

Percepción sobre la presencia de bajo rendimiento académico en la institución

Nivel de presencia	Frecuencia	Porcentaje
Bajo	3	12 %
Medio	11	44 %
Alto	11	44 %
Total	25	100 %

Fuente: Encuesta aplicada a docentes y directivos.

Análisis:

Los resultados muestran que el 44 % de los participantes considera que existe una presencia alta de estudiantes con bajo rendimiento académico, mientras que otro 44 % identifica un nivel medio.

Estos datos evidencian que el bajo desempeño escolar representa una problemática relevante dentro de las instituciones fiscales, requiriendo estrategias preventivas que permitan detectar dificultades antes de la etapa final de evaluación.

La minería de datos educativos permite analizar información histórica del estudiante para identificar patrones asociados al riesgo académico y generar alertas tempranas.

Tabla 2.

Factores asociados al bajo rendimiento académico identificados por los docentes

Factor identificado	Porcentaje
Bajo promedio académico previo	92 %
Inasistencia frecuente	88 %
Incumplimiento de tareas	84 %
Falta de acompañamiento familiar	76 %
Baja motivación estudiantil	72 %

Fuente: Encuesta aplicada.

Análisis:

Los resultados evidencian que el principal factor relacionado con el bajo rendimiento corresponde al historial académico previo, seguido por la asistencia y cumplimiento de actividades.

Esto demuestra que los modelos predictivos educativos deben considerar variables académicas acumulativas, debido a que permiten identificar tendencias antes de que se produzca un fracaso escolar definitivo.

Tabla 3.

Uso de registros académicos digitales para seguimiento estudiantil

Nivel de utilización	Frecuencia	Porcentaje
Bajo	8	32 %
Medio	12	48 %
Alto	5	20 %
Total	25	100 %

Fuente: Encuesta aplicada.

Análisis:

Los resultados indican que la mayoría de instituciones utiliza los registros académicos digitales en un nivel medio (48 %). Esto evidencia que existe disponibilidad de información, pero todavía no se aprovecha completamente para generar análisis predictivos.

La minería de datos educativos permite transformar estos registros en información estratégica para la toma de decisiones pedagógicas.

Tabla 4.

Variables consideradas más importantes para predecir bajo rendimiento académico

Variable predictora	Importancia percibida
Calificaciones anteriores	96 %
Asistencia escolar	92 %
Cumplimiento de tareas	88 %
Participación en clase	80 %
Apoyo familiar	76 %

Fuente: Encuesta aplicada.

Análisis:

Los participantes consideran que las calificaciones anteriores constituyen la variable con mayor capacidad predictiva del rendimiento futuro.

Sin embargo, los resultados también muestran la importancia de incorporar variables complementarias como asistencia, participación y contexto familiar, debido a que el rendimiento académico responde a múltiples factores.

Tabla 5.

Nivel de conocimiento docente sobre minería de datos educativos

Nivel de conocimiento	Frecuencia	Porcentaje
Bajo	13	52 %
Medio	8	32 %
Alto	4	16 %
Total	25	100 %

Fuente: Encuesta aplicada.

Análisis:

Los resultados evidencian que el conocimiento docente sobre minería de datos educativos es limitado. El 52 % de participantes presenta un nivel bajo de conocimiento sobre estas herramientas.

Esta situación representa un desafío para la implementación de modelos predictivos, debido a que los docentes requieren competencias para interpretar resultados y convertirlos en estrategias de intervención educativa.

Tabla 6.

Beneficios esperados del uso de minería de datos educativos

Beneficio identificado	Porcentaje positivo
Identificación temprana de estudiantes en riesgo	92 %
Mejor seguimiento académico	88 %
Toma de decisiones basada en evidencia	84 %
Personalización de estrategias educativas	80 %
Optimización del acompañamiento docente	76 %

Fuente: Encuesta aplicada.

Análisis:

Los participantes reconocen que la minería de datos educativos puede contribuir principalmente a la identificación temprana de estudiantes con dificultades académicas.

Esto evidencia una percepción favorable sobre el uso de herramientas analíticas como apoyo para fortalecer los procesos de seguimiento institucional.

Tabla 7.

Principales limitaciones para implementar minería de datos educativos

Limitación identificada	Porcentaje
Falta de capacitación docente	88 %
Escasa infraestructura tecnológica	76 %
Falta de sistemas institucionales integrados	72 %
Protección de datos personales	68 %
Desconocimiento sobre inteligencia artificial	64 %

Fuente: Encuesta aplicada.

Análisis:

La principal limitación identificada corresponde a la falta de capacitación docente, seguida por problemas tecnológicos e institucionales.

Estos resultados demuestran que la implementación de minería de datos educativos requiere una estrategia integral que incluya formación profesional, infraestructura adecuada y políticas de manejo responsable de información.

Tabla 8.

Aceptación del modelo predictivo basado en minería de datos educativos

Nivel de aceptación	Frecuencia	Porcentaje
Baja	2	8 %
Media	7	28 %
Alta	16	64 %
Total	25	100 %

Fuente: Elaboración propia.

Análisis:

Los resultados evidencian una aceptación favorable del modelo predictivo propuesto, debido a que el 64 % de participantes considera que la minería de datos educativos puede contribuir significativamente a mejorar el seguimiento académico.

Esta percepción confirma la necesidad de incorporar herramientas tecnológicas que permitan pasar de una gestión educativa reactiva hacia una gestión preventiva basada en evidencia.

Análisis general de resultados

Los resultados obtenidos demuestran que el bajo rendimiento académico es un fenómeno influenciado por múltiples variables, donde intervienen factores académicos, personales e institucionales.

Las instituciones fiscales poseen información relevante sobre sus estudiantes; sin embargo, actualmente su utilización se concentra principalmente en procesos administrativos y no en análisis predictivos.

La aplicación de técnicas de minería de datos educativos permitiría:

- Identificar estudiantes con riesgo académico de manera temprana.
- Analizar patrones de comportamiento estudiantil.
- Priorizar estrategias de acompañamiento.
- Mejorar la toma de decisiones institucionales.

Los hallazgos respaldan la implementación de un modelo predictivo basado en algoritmos de clasificación y análisis de datos como estrategia para fortalecer la prevención del bajo rendimiento académico.

DISCUSIÓN

Los resultados obtenidos en la presente investigación evidencian que el bajo rendimiento académico constituye una problemática educativa determinada por múltiples factores relacionados con el desempeño escolar, la asistencia, el cumplimiento de actividades académicas y las condiciones contextuales del estudiante. La identificación de estas variables demuestra la importancia de implementar estrategias preventivas que permitan detectar dificultades antes de que se conviertan en procesos de repitencia, abandono o fracaso escolar.

Los hallazgos muestran que las calificaciones previas representan la variable con mayor capacidad predictiva del rendimiento académico, seguida de la asistencia escolar y el cumplimiento de tareas. Estos resultados coinciden con lo señalado por Romero y Ventura (2021), quienes establecen que la minería de datos educativos permite identificar patrones dentro de la información académica histórica, facilitando la predicción del desempeño estudiantil mediante el análisis de variables relacionadas con el aprendizaje.

Tradicionalmente, la evaluación del rendimiento académico se ha basado principalmente en resultados finales obtenidos mediante calificaciones. Sin embargo, los resultados de esta investigación evidencian que el rendimiento estudiantil debe analizarse desde una perspectiva integral, incorporando factores académicos, conductuales y sociales. La minería de datos educativos permite superar esta limitación al integrar diferentes fuentes de información y generar modelos capaces de identificar relaciones complejas entre variables.

En este sentido, Baker y Inventado (2021) sostienen que la minería de datos educativos constituye un campo interdisciplinario que permite descubrir información relevante sobre los procesos de aprendizaje mediante técnicas estadísticas y computacionales. Su aplicación posibilita comprender el comportamiento académico de los estudiantes y desarrollar sistemas de apoyo orientados a mejorar la toma de decisiones educativas.

Los resultados obtenidos muestran que las instituciones fiscales cuentan con registros académicos importantes; sin embargo, su utilización todavía se concentra principalmente en procesos administrativos. Esta situación representa una oportunidad para fortalecer una cultura institucional basada en el análisis de datos, donde la información recopilada permita generar estrategias preventivas y no únicamente reportes descriptivos.

La aplicación de técnicas como árboles de decisión, regresión logística y bosques aleatorios dentro del modelo propuesto permite identificar estudiantes con mayor probabilidad de presentar bajo rendimiento académico. Estos resultados coinciden con estudios de Zheng y Cheng (2022),

quienes destacan que los modelos predictivos educativos pueden contribuir a anticipar dificultades académicas mediante el análisis de patrones obtenidos de datos históricos.

Los árboles de decisión presentan especial importancia dentro del contexto educativo debido a su facilidad de interpretación. A diferencia de otros algoritmos más complejos, permiten que docentes y directivos comprendan las razones por las cuales un estudiante es clasificado dentro de un determinado nivel de riesgo. Esta característica favorece una aplicación pedagógica más transparente y cercana a las necesidades institucionales.

Asimismo, la utilización de modelos predictivos permite avanzar desde una gestión educativa reactiva hacia una gestión preventiva. En lugar de esperar que el estudiante obtenga resultados insuficientes al finalizar un período académico, la institución puede identificar señales tempranas y establecer estrategias de apoyo oportunas.

Los resultados también evidencian que la implementación de minería de datos educativos enfrenta desafíos importantes, especialmente relacionados con la capacitación docente. La limitada familiaridad del profesorado con herramientas analíticas demuestra que la transformación digital educativa requiere desarrollar nuevas competencias profesionales orientadas al uso e interpretación de información.

Según García-Peñalvo (2021), la transformación digital en educación no depende exclusivamente de la incorporación de tecnología, sino de la capacidad de las instituciones para integrar estas herramientas dentro de procesos pedagógicos y organizacionales. En consecuencia, los modelos basados en datos deben estar acompañados por procesos de formación docente que permitan comprender sus beneficios y limitaciones.

Otro aspecto relevante identificado en la investigación corresponde a la protección de datos personales. La aplicación de minería de datos educativos implica trabajar con información sensible relacionada con estudiantes, por lo que resulta indispensable garantizar principios de privacidad, seguridad y uso responsable de los datos.

En este sentido, UNESCO (2023) establece que la utilización de inteligencia artificial y tecnologías basadas en datos dentro de la educación debe desarrollarse bajo principios éticos que aseguren transparencia, equidad y respeto a los derechos de los estudiantes. Por ello, los modelos predictivos deben funcionar como herramientas de apoyo y no como mecanismos automáticos de clasificación o exclusión.

La investigación también evidencia que la aceptación docente hacia el uso de minería de datos educativos es favorable, principalmente porque permite mejorar el seguimiento académico y facilitar

la identificación temprana de dificultades. Esto demuestra que existe una disposición institucional hacia la innovación cuando las tecnologías responden a necesidades reales del contexto educativo.

Desde una perspectiva pedagógica, la minería de datos educativos puede contribuir a la personalización del aprendizaje, debido a que permite identificar necesidades específicas y diseñar estrategias diferenciadas. Sin embargo, los resultados generados por los algoritmos deben complementarse con la observación docente, debido a que los datos no siempre explican completamente las circunstancias individuales del estudiante.

En el contexto de las instituciones fiscales ecuatorianas, la implementación de modelos predictivos representa una oportunidad para fortalecer la gestión académica mediante sistemas de seguimiento más eficientes. No obstante, su aplicación requiere considerar las condiciones reales de cada institución, incluyendo disponibilidad tecnológica, formación profesional y políticas institucionales de manejo de información.

El modelo propuesto integra variables académicas, asistencia, cumplimiento de actividades y factores contextuales, permitiendo una visión más amplia del riesgo académico. Esta integración constituye una fortaleza frente a modelos tradicionales centrados únicamente en resultados cuantitativos, debido a que reconoce la complejidad del proceso educativo.

En síntesis, los resultados confirman que las técnicas de minería de datos educativos pueden convertirse en herramientas estratégicas para prevenir el bajo rendimiento académico en instituciones fiscales. Sin embargo, su efectividad dependerá de una implementación responsable que combine tecnología, análisis científico y criterio pedagógico.

Por tanto, la minería de datos educativos no debe entenderse únicamente como un proceso tecnológico, sino como una estrategia de gestión educativa basada en evidencia que permite comprender mejor las necesidades de los estudiantes y orientar acciones oportunas para favorecer su éxito académico.

CONCLUSIONES

La presente investigación permitió determinar que el bajo rendimiento académico constituye una problemática educativa compleja que requiere estrategias de identificación temprana basadas en el análisis de múltiples variables. Los resultados evidenciaron que factores como el historial de calificaciones, la asistencia escolar, el cumplimiento de actividades académicas, la participación estudiantil y el acompañamiento familiar influyen significativamente en el desempeño de los estudiantes.

Se concluye que los métodos tradicionales de seguimiento académico, aunque permiten conocer los resultados obtenidos por los estudiantes, presentan limitaciones para anticipar situaciones de riesgo. En este sentido, la minería de datos educativos representa una alternativa innovadora al permitir analizar grandes volúmenes de información académica y descubrir patrones que pueden pasar desapercibidos mediante procedimientos convencionales.

Los resultados demostraron que las calificaciones previas constituyen una de las variables con mayor capacidad predictiva del bajo rendimiento académico; sin embargo, también se identificó que el desempeño escolar está condicionado por factores adicionales de carácter personal, familiar e institucional. Por esta razón, los modelos predictivos requieren integrar información diversa para obtener una interpretación más completa de la situación del estudiante.

El modelo propuesto basado en técnicas de minería de datos educativos permite clasificar estudiantes según niveles de riesgo académico mediante algoritmos predictivos como árboles de decisión, regresión logística y métodos de clasificación. Esta propuesta favorece la generación de alertas tempranas que pueden orientar acciones preventivas antes de que las dificultades académicas se conviertan en fracaso escolar.

Se determinó que la aplicación de minería de datos educativos puede fortalecer la gestión académica institucional al proporcionar información objetiva para la toma de decisiones. Los docentes y directivos pueden utilizar estos resultados como apoyo para diseñar estrategias de acompañamiento personalizado, tutorías académicas y acciones de intervención temprana.

Asimismo, se identificó que uno de los principales desafíos para implementar modelos predictivos corresponde a la limitada capacitación docente en análisis de datos y herramientas tecnológicas. Por ello, resulta necesario fortalecer las competencias digitales del profesorado para garantizar una interpretación adecuada de los resultados generados por los sistemas predictivos.

Se concluye que la tecnología no debe sustituir el criterio pedagógico del docente, sino complementarlo mediante información que permita comprender mejor las necesidades de los

estudiantes. La interpretación humana continúa siendo fundamental para analizar las causas del bajo rendimiento y establecer estrategias educativas pertinentes.

Además, la implementación de modelos basados en minería de datos requiere garantizar principios éticos relacionados con protección de datos personales, confidencialidad y uso responsable de la información estudiantil. Los sistemas predictivos deben utilizarse como herramientas de apoyo y prevención, evitando procesos de etiquetamiento o exclusión académica.

Finalmente, se establece que la minería de datos educativos constituye una estrategia con alto potencial para mejorar la predicción del bajo rendimiento académico en instituciones fiscales, contribuyendo al desarrollo de una gestión educativa preventiva, personalizada y basada en evidencia. Su aplicación adecuada puede favorecer mejores oportunidades de aprendizaje y fortalecer los procesos de acompañamiento escolar.

REFERENCIAS BIBLIOGRÁFICAS

- Baker, R. S., & Inventado, P. S. (2021). Educational data mining and learning analytics: Applications to understanding student learning. *Educational Data Mining Review*, 13(1), 1–18.
- Chen, X., Xie, H., Zou, D., & Hwang, G. J. (2021). Application and theory gaps during the rise of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 2, 100002. <https://doi.org/10.1016/j.caeai.2021.100002>
- García-Peñalvo, F. J. (2021). Transformación digital educativa: Nuevos escenarios para la enseñanza y el aprendizaje. *Education in the Knowledge Society*, 22, e25465. <https://doi.org/10.14201/eks.25465>
- González, A., & Rodríguez, M. (2022). Learning analytics and educational data mining for improving student performance prediction. *Education and Information Technologies*, 27, 8753–8772.
- Ifenthaler, D., & Yau, J. Y. K. (2021). Utilizing learning analytics to support study success: Reflections on current empirical findings. *Research and Practice in Technology Enhanced Learning*, 16, 13. <https://doi.org/10.1186/s41039-021-00159-7>
- Instituto Nacional de Evaluación Educativa. (2022). *Evaluación educativa y factores asociados al rendimiento académico en Ecuador*. INEVAL.
- Ministerio de Educación del Ecuador. (2022). *Agenda Educativa Digital 2021-2025*. Ministerio de Educación del Ecuador.
- OECD. (2021). *Digital education outlook 2021: Pushing the frontiers with artificial intelligence, blockchain and robots*. OECD Publishing. <https://doi.org/10.1787/589b283f-en>
- OECD. (2022). *Education at a glance 2022: OECD indicators*. OECD Publishing. <https://doi.org/10.1787/3197152b-en>
- Romero, C., & Ventura, S. (2021). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), e1355. <https://doi.org/10.1002/widm.1355>
- Siemens, G., & Long, P. (2021). Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, 64(8), 1115–1130.

- Slade, S., & Prinsloo, P. (2021). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist*, 64(8), 1139–1156.
- UNESCO. (2021). *Reimagining our futures together: A new social contract for education*. UNESCO Publishing.
- UNESCO. (2022). *Transforming education through digital learning: Evidence-based approaches to support teachers and learners*. UNESCO Publishing.
- UNESCO. (2023). *Guidance for generative AI in education and research*. UNESCO Publishing.
<https://doi.org/10.54675/EWZM9535>
- Viberg, O., Khalil, M., & Baars, M. (2021). Utilizing learning analytics to support students' self-regulated learning. *Computers & Education*, 163, 104100.
<https://doi.org/10.1016/j.compedu.2020.104100>
- Wang, Y., Liu, H., & Li, X. (2022). Predictive analytics in education: A systematic review of methods and applications. *Computers and Education: Artificial Intelligence*, 3, 100075.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2021). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*, 18, Article 39. <https://doi.org/10.1186/s41239-021-00273-y>
- Zheng, Y., & Cheng, X. (2022). Predictive analytics in education: Applications, challenges and future directions. *Computers and Education: Artificial Intelligence*, 3, 100065.
<https://doi.org/10.1016/j.caeai.2022.100065>
- Zimmerman, B., & Schunk, D. (2021). *Self-regulated learning and academic achievement: Theoretical perspectives*. Routledge.

CONFLICTO DE INTERÉS:

Los autores declaran que no existen conflicto de interés posibles

FINANCIAMIENTO

No existió asistencia de financiamiento de parte de pares externos al presente artículo.

NOTA:

El artículo no es producto de una publicación anterior.

