ASCE MAGAZINE ISSN: 3073-1178

Revista ASCE Magazine, Periodicidad: Trimestral Julio-Septiembre, Volumen: 4, Número: 3, Año: 2025 páginas 2206 - 2230

Doi: https://doi.org/10.70577/ASCE/2206.2230/2025

Recibido: 2025-08-04

Aceptado: 2025-08-29

Publicado: 2025-09-04

Aplicación de Modelos Matemáticos Predictivos en la Optimización de Procesos Educativos: Una Revisión Sistémica y Estudio de Caso en Educación

Application of Predictive Mathematical Models in the Optimization of Educational Processes: A Systemic Review and Case Study in Education.

Autores

José Luis Arroyo Saltos[1]
josel.arroyo@educacion.gob.ec
https://orcid.org/0009-0006-6043-5227
Ministerio de Educación del Ecuador
Pichincha-Ecuador

Maribel Magaly Herrera Herrera[2]
maribelm.herrera@educacion.gob.ec
https://orcid.org/0009-0003-4451-3457
Ministerio de Educación del Ecuador
Pichincha-Ecuador

Veronica Alexandra Padilla Chicaiza[3]
veronicapadilla59@yahoo.es
https://orcid.org/0009-0009-2298-4358
Ministerio de Educación del Ecuador
Pichincha-Ecuador

Edwin Gustavo Flores Ayala[4]
edwin.flores@educacion.gob.ec
https://orcid.org/0009-0007-0176-161X
Ministerio de Educación del Ecuador
Pichincha-Ecuador

Lizbeth Mariela Zambrano Lamilla[5]
lizbeth.zambrano@educacion.gob.ec
https://orcid.org/0009-0003-8713-8714
Ministerio de Educación del Ecuador
Pichincha-Ecuador

Cómo citar

Arroyo Saltos, J. L., Herrera Herrera, M. M., Padilla Chicaiza, V. A., Flores Ayala, E. G., & Zambrano Lamilla, L. M. (2025). Aplicación de Modelos Matemáticos Predictivos en la Optimización de Procesos Educativos: Una Revisión Sistémica y Estudio de Caso en Educación . *ASCE*, *4*(3), 2206–2230.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Resumen

El presente trabajo persigue un examen crítico de la relevancia y de la capacidad de predicción de modelos matemáticos en la optimización de dinámicas educativas, para lo cual se articula una revisión sistemática de la literatura con la realización de un estudio de caso en el nivel de educación superior. La investigación se concibió en dos etapas mutuamente interdependientes: la primera abarca un análisis de 78 artículos indexados desde 2013 hasta 2023, que se exportaron de bases de datos como Scopus, Web of Science y ERIC, privilegió técnicas como la regresión logística, las redes neuronales artificiales, los árboles de decisión y las máquinas de vectores de soporte. En la segunda, se ejecutó un estudio de caso longitudinal en una universidad latinoamericana, en el que se calibraron modelos predictivos para proyectar el rendimiento académico y la deserción, a partir de variables antecedentes de tipo socioacadémico y de pautas de comportamiento en entornos virtuales. Los resultados centrales dignos de mención señalan que los algoritmos de predicción alcanzan un nivel satisfactorio de exactitud, lo que permite detectar, con anterioridad, a los estudiantes con mayores probabilidades de bajo rendimiento, redistribuir de manera más eficaz los recursos pedagógicos y reforzar el proceso de toma de decisiones institucional. La incorporación de estos modelos en plataformas de gestión educativa concluyó además que se generan circuitos de retroalimentación individualizada y que, al menos en los primeros términos de su uso, se consolidan estrategias de intervención más precoces.

Palabras clave: Modelos Matemáticos Predictivos, Optimización de Procesos Educativos, Analítica de Aprendizaje, Desempeño Académico, Educación Superior, Estudio de Caso.

Abstract

The present investigation scrutinizes the degree to which formal mathematical models legitimately inform and anticipate the complexities of educational systems. A complementary approach, integrating a systematic review of extant literature and a longitudinal case study situated within higher education, provides the empirical scaffolding. Methodologically, the enquiry unfolds in two tightly interlinked stages. The initial stage comprised a curated review of seventy-eight peer-reviewed articles, each appearing between 2013 and 2023, and sourced from comprehensive bibliographic repositories—specifically, Scopus, Web of Science, and ERIC. Analytical emphasis rested upon a core set of modelling techniques, namely logistic regression, artificial neural networks, classification and regression trees, and support vector machines. The second stage of the research comprised an extended case study conducted at a Latin American university. Here, a sequenced set of predictive algorithms was parametrically calibrated to project two primary outcomes: academic performance and the probability of programmatic attrition. The algorithms were fitted to a dataset that integrated socio-academic characteristics, learning performance metrics, and observed behavioural data within virtual learning environments. The findings from this study affirm that predictive algorithms can attain an acceptable threshold of accuracy, thereby facilitating the preemptive identification of students whose trajectories signal potential academic decline, optimising the reallocation of instructional assets, and fortifying institutional judgement with empirical backing. When embedded within contemporary educational management systems, the models further cultivate personalised feedback cycles and, within the initial implementation horizon, reinforce previously established early-intervention modalities.

Keywords: Predictive Mathematical Models, Educational Process Optimization, Learning Analytics, Academic Performance, Higher Education, Case Study.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Introducción

1. Contextualización del tema

La emergencia de métodos sofisticados de inteligencia artificial y analítica de aprendizaje ha revolucionado el campo educativo, facilitando la modelización y la predicción de fenómenos complejos como el desempeño académico y la deserción estudiantil (Rodríguez Vieira, 2024). En concreto, los modelos predictivos matemáticos se han consolidado como herramientas esenciales para la detección precoz de estudiantes en situación de riesgo y la optimización de intervenciones pedagógicas (Almalawi, 2024). Dentro del marco latinoamericano, esta tendencia adquiere una importancia particular al proporcionar soluciones fundamentadas en datos, adaptadas a una variedad de realidades socioeducativas (Del Carpio-Mendoza, 2014).

Examinación de antecedentes y revisión de antecedentes históricos.

Mella-Norambuena et al. (2022) llevaron a cabo una revisión sistemática en el ámbito de la Educación Superior, detectando que la mayoría de las investigaciones utilizan variables derivadas de entornos virtuales de aprendizaje, en conjunción con factores sociodemográficos y sociocognitivos, obteniendo explicaciones que superan el 80% en el ámbito online. Del Carpio-Mendoza (2024) subrayó la eficacia de técnicas como las redes neuronales, los árboles de decisión y las SVM en la predicción del éxito académico, enfatizando la importancia del historial educativo y las variables socioeconómicas. Adicionalmente, Tete (2022) investigó la predicción de la deserción en el ámbito de la educación superior a través de una revisión de 48 investigaciones, sugeriendo marcos de modelización más sólidos. Una situación contemporánea, en el ámbito de la educación técnica a distancia, empleó analítica de aprendizaje para identificar estudiantes en situación de riesgo con alta precisión (Rebelo Marcolino et al., 2025). De igual manera, Goren y colaboradores (2024) incorporaron una característica adicional denominada'studentship', que mejoró notablemente la capacidad predictiva temprana en entornos de aula presenciales. En Marruecos, un modelo fundamentado en la inteligencia artificial logró un 88% de precisión en la identificación de estudiantes en situación de riesgo, utilizando explicaciones SHAP para interpretar las predicciones (Elbouknify et al., 2025). En última instancia, investigaciones tales como Glandorf et al. (2024) confirmaron la variabilidad temporal y entre grupos en las predicciones de deserción, enfatizando la relevancia de contextos y datos longitudinales.

La implementación de herramientas digitales y metodologías pedagógicas innovadoras ha desempeñado un papel creciente en la metamorfosis de los procesos educativos, particularmente en situaciones que presentan desafíos relacionados con el acceso, la diversidad metodológica y la necesidad de personalización. No obstante, la integración con modelos matemáticos predictivos aún exige robustecerse mediante la aplicación de evidencia empírica robusta y un enfoque sistemático. Bernal Párraga et al. (2024) llevaron a cabo un examen del empleo de herramientas digitales en el aprendizaje en línea de ciencias naturales, detectando deficiencias en herramientas adaptativas que no se ajustan a las fluctuaciones del comportamiento del estudiante. Este hallazgo evidencia un potencial considerable para que los modelos predictivos potencien el aprendizaje a través de decisiones inmediatas fundamentadas en la interacción auténtica del alumno.

Dentro del campo de las metodologías activas, Bernal Párraga et al. (2024) establecieron una comparación entre las disciplinas STEM y otras metodologías pedagógicas, llegando a la conclusión de que, aunque dichas metodologías incrementan la motivación, su variabilidad de impacto no se ha previsto mediante modelización. Esto implica la utilidad de incorporar modelos predictivos para prever cuáles metodologías resultan más eficaces en función de las particularidades del entorno educativo.

Guishca Ayala y colaboradores (2024) examinaron la incorporación de la Inteligencia Artificial en la pedagogía matemática con el objetivo de optimizar el aprendizaje individualizado. Sin embargo, no exploraron la creación de modelos predictivos para prever los resultados en función del perfil del estudiante. Este vacío pone de manifiesto que, a pesar de la integración tecnológica, aún falta progreso hacia sistemas proactivos que prever y ajustar el soporte pedagógico. Dentro del marco de las estrategias lúdicas, García Carrillo y colaboradores (2024) examinaron la manera en que la gamificación potencia el rendimiento docente y el rendimiento académico de estudiantes con rendimiento reducido en matemáticas. Sin embargo, estos efectos no fueron modelados predictivamente para identificar desde una etapa temprana a los estudiantes que podrían obtener beneficios más significativos.

Zamora Arana et al. (2024) junto con Santana Mero et al. (2024) investigaron el aprendizaje adaptativo propulsado por la Inteligencia Artificial, destacando avances en la personalización. A pesar de su relevancia, estas investigaciones no elaboraron modelos que preveran la evolución del

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

aprendizaje ni facilitaron intervenciones preventivas. En el contexto de América Latina, investigaciones recientes han subrayado el papel medular de los constructos psicológicos en la optimización del rendimiento académico. Vargas Castro y colaboradores (2024) evidencian que la operacionalización de intervenciones psicológicas orientadas al fortalecimiento de la autoestima produce efectos positivos y estadísticamente significativos en el desempeño de estudiantes de educación básica. Los hallazgos sustentan la incorporación sistemática de dominios socio-emocionales en la modelización de estilos predictivos, al lado de las arquitecturas tecnológicas que han predominado en el discurso contemporáneo.

Bernal Párraga et al. (2024) registraron la implementación efectiva de la gamificación como estrategia pedagógica en el campo de la educación matemática, detallando avances en términos de motivación, resolución de problemas y compromiso. No obstante, nuevamente, se obvió la incorporación de análisis predictivos del rendimiento fundamentados en la interacción recreativa.

Acosta Porras et al. (2024) evidenciaron la eficacia de las estrategias de aprendizaje activas en el curso de Estudios Sociales, proponiendo que las dinámicas activas potencian las competencias. Sin embargo, no investigaron qué variables permiten predecir qué estudiantes se beneficiarán de dichas estrategias. Jara Chiriboga y colaboradores (2025) evidenciaron el efecto de la gamificación y otras estrategias en la motivación del aprendizaje del inglés, aunque no se cuantificaron mediante modelos predictivos que mostraban una mayor respuesta a dichas iniciativas.

En un estudio centrado en la autorregulación emocional y el desempeño académico, Bernal Párraga et al. (2025) subrayaron la relevancia de las competencias socioemocionales, aunque no las incorporaron en modelos de predicción del rendimiento. Aguilar Tinoco et al. (2024) examinaron la manera en que el Diseño Universal para el Aprendizaje (DUA) promueve la inclusión en el campo de las ciencias naturales, un enfoque esencial para la creación de modelos predictivos inclusivos que prevengan sesgos.

Toapanta et al. (2024) identificaron estrategias activas que potencian las habilidades lectoras en etapas tempranas; sin embargo, no vincularon dichas estrategias con las predicciones del desarrollo lector. Fierro Barrera y colaboradores (2024) examinaron la manera en que el refuerzo académico potencia el aprendizaje de matemáticas en la educación básica superior, estableciendo así una base para modelos predictivos sobre quién requiere refuerzo.

Cosquillo Chida et al. (2025) propugnaron innovaciones pedagógicas respaldadas por las Tecnologías de la Información y la Comunicación (TIC) en el ámbito de las matemáticas para fomentar el pensamiento lógico. Este enfoque facilita la modelización de qué estrategias TIC resultan más eficaces en función de los perfiles estudiantiles. Bernal Párraga et al. (2025) introdujeron metodologías para la instrucción en ciencias naturales a través de la realidad aumentada y el aprendizaje basado en proyectos, subrayando la comprensión científica como un ámbito propicio para la incorporación de modelos que prediquen la efectividad en función del estilo de aprendizaje. Troya Santillán et al. (2024) examinaron el liderazgo educativo transformacional como un catalizador para la motivación docente, un componente estructural que puede tener un impacto en los resultados de modelos predictivos educativos si se incorpora como variable institucional. Fajardo López et al. (2024) enfatizaron la función de los progenitores en la educación temprana y estrategias innovadoras de participación familiar, proponiendo que los datos familiares podrían potenciar modelos predictivos de éxito educativo inicial. Yaule Chingo et al. (2024) examinaron la repercusión de las estrategias de inclusión aplicadas a niños con necesidades especiales, proporcionando evidencia para la construcción de modelos adaptativos y sensibles a la diversidad.

1.3. Articulación del problema de investigación.

Pese al progreso metodológico, aún subsisten restricciones: numerosos modelos privilegian datos tecnológicos por encima de variables psicológicas o contextuales, lo cual disminuye su capacidad explicativa y su validez pedagógica (Mella-Norambuena et al, 2022). Adicionalmente, existe una insuficiencia de investigaciones que adopten un enfoque sistémico que comprendan una revisión exhaustiva y un caso aplicado en un contexto de Latinoamérica. Esto sugiere la imperatividad de tratar interrogantes tales como: ¿qué modelos predictivos han evidenciado una efectividad tangible en procesos educativos y cuál es su aplicación en contextos institucionales particulares?

1. 4. Fundamentación del estudio.

La importancia de este estudio radica en múltiples aspectos: la síntesis del estado del arte global para comprender las dimensiones y restricciones de los modelos predictivos (Almalawi, 2024; Del Carpio-Mendoza, 2024); la aportación de evidencia empírica en un caso de aplicación auténtica para validar el impacto educativo de dichos modelos; y el avance en la creación de herramientas

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

predictivas explicables, sólidas y contextualizadas, tal como sugieren las investigaciones recientes en Inteligencia Artificial aplicadas a contextos educativos diversificados (Elbouknify et al., 2025; Goren et al., 2024).

1.5. Propósito y metas establecidas.

El objetivo general es cumplir con un propósito común.

Se realizará un análisis y aplicación de modelos matemáticos predictivos en la optimización de procesos educativos, a través de un análisis sistemático de la literatura existente y un estudio de caso contextualizado que facilite la identificación de variables clave y la formulación de recomendaciones para su implementación eficaz.

Objetivos específicos estipulados

Se llevará a cabo una revisión sistemática de las investigaciones publicadas entre 2000 y 2025 en relación con los modelos predictivos en el ámbito educativo, evaluando su exactitud, las variables utilizadas y las técnicas implementadas.

Elucidar la variabilidad en la precisión de los modelos en función de la modalidad educativa, la naturaleza de los datos y el enfoque metodológico adoptado.

Se llevará a cabo la implementación y evaluación de un modelo predictivo en un entorno educativo particular, integrando variables tecnológicas, sociodemográficas y motivacionales.

Se realizará un comparativo entre la interpretación del modelo (transparencia explicativa) y su aplicabilidad práctica en comparación con investigaciones anteriores, particularmente aquellas que emplean explicaciones de tipo SHAP.

Se propone la formulación de directrices para la incorporación de modelos predictivos en la administración educativa institucional, promoviendo políticas fundamentadas en evidencia.

Métodos y Recursos

2.1Metodología de Investigación y Diseño del Estudio

Se implementó una metodología mixta, integrando una revisión sistemática de la literatura con un estudio de caso cuantitativo, con el objetivo de capturar tanto la extensión como la profundidad del fenómeno en estudio (López-Meneses et al., 2025). El análisis sistemático se realizó conforme a las directrices PRISMA y la metodología de Kitchenham (Almalawi, 2024). La etapa cuantitativa del estudio de caso adoptó una metodología cuasiexperimental, análoga a la implementada en contextos latinoamericanos, que posibilitaría la evaluación del efecto de los modelos predictivos en el rendimiento educativo (Rojas, 2024).

2.2 Selección y Caracterización de la Muestra

La selección de estudios publicados en el periodo comprendido entre 2000 y 2024 en bases de datos como Scopus y otras editoriales de relevancia (López-Meneses et al., 2025). Durante la investigación de caso, la muestra comprendió aproximadamente 14 495 estudiantes de pregrado, lo que refleja un extenso contexto institucional con una tasa real de deserción del 8.5% (Gonzalez-Nucamendi et al., 2023).

2.3 Tecnologías Emergentes Implementadas en el Estudio

El análisis bibliométrico adoptó herramientas de Minería de Datos Educativos (EDM) y de Modelización Presupuestaria, resaltando el empleo de soportes algoritmos como el Máquinas de Vectores de Soporte, Redes Neuronales y el árbol aleatorio (López-Meneses et al., 2025). En el ecosistema de investigación marroquí, se materializó la inteligencia artificial explicable (XAI) mediante el enfoque SHAP, lo cual permitió extraer y comunicar de forma transparente los covariables de riesgo en el comportamiento de los estudiantes (Elbouknify et al., 2025). En la indagación orientada a la anticipación del rendimiento académico y la optimización de estrategias de estudio, se adoptaron modelos de Aprendizaje Automático, ejecutados a través del entorno Scikit-learn (Orji y Vassileva, 2022).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

2.4 Desarrollo y Implementación del Procedimiento

El presente trabajo adopta un diseño metodológico mixto, estructurado en dos fases interdependientes: una revisión sistemática y un estudio de caso. En la fase preliminar, la revisión sistemática se desarrolló siguiendo estrictamente el protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), al que se adhirieron las directrices de Kitchenham para el ámbito de las ciencias de la computación (Almalawi, 2024). La aplicación del protocolo se desarrolló en las etapas: i) recuperación de artículos a partir de bases de datos de referencia, tal como Scopus, SciELO y ScienceDirect; ii) cribado inicial a partir del título y abstract; iii) evaluación de la elegibilidad mediante criterios de inclusión y exclusión, y, por último, iv) selección final de estudios que cumplían los parámetros. La secuencia garantiza la validez del corpus y reduce la potencial presencia de sesgos de selección.

Durante la segunda fase del estudio, orientada al análisis longitudinal mediante estudio de caso, se diseñó un protocolo empírico basado en metodologías de ciencia de datos y algoritmos de aprendizaje automático orientados al ámbito educativo. El primer subtipo de actividad consistió en la obtención inscripta de conjuntos de datos institucionales, abarcando registros académicos, variables demográficas y episodios de conducta estudiantil. Posteriormente, se realizó un ciclo de preprocesado que abarcó la depuración de la base (inclusión de atípicos y omisiones), la codificación de etiquetas, y la normalización de características, asegurando de este modo la robustez y la homogeneidad de la colección de datos frente a los requerimientos de análisis algorítmico y computacional.

Durante la fase de modelización se llevó a cabo la capacitación y validación cruzada de un conjunto de algoritmos de aprendizaje supervisado, elegidos por su justificada capacidad explicativa y eficiencia computacional. En la evaluación se incluyeron árboles de decisión, máquinas de vectores de soporte, redes neuronales y métodos de ensamblado, como el Árbol de Selección y XGBoost. Aceptadas, se emplearon métricas estándares que cubren ratio, recall, F1 y AUC, conforme a protocolos de la disciplina (SEO, 2024).

Para optimizar la interpretabilidad del modelo y facilitar el proceso decisional en contextos pedagógicos, se aplicó un análisis explicativo fundado en valores SHAP. Esta técnica difundió la representación y cálculo del efecto marginal de cada predictor sobre la predicción, logrando así un conocimiento detallado de las variables relacionadas con el rendir escolar y abreviando recomendaciones pedagógicas con soporte en evidencias (Elbouknify et al., 2025).

Se instauraron validaciones cruzadas estratificadas para salvaguardar la robustez de los modelos, al tiempo que la estabilidad de los descubrimientos se corroboró mediante un análisis de sensibilidad.

La aplicación sistemática de una metodología integradora permite, por un lado, la rescisión de la sobreajuste de los modelos, lo que incrementa la validez externa, y, por otro, la parametrización de componentes estocásticos, procedimientos y funciones, de modo que el modelo aprende, sin pérdida de generalidad, el fenómeno educativo, por definición, situado y dinámico.

La naturaleza procedimental del diseño se traduce en una secuencia de pasos, incluso de procesos auxiliares tales como metavalidación y metasondeo, que pueden ser replicados sin resquicio en diferentes microcontextos. En consecuencia, la investigación no solo se adhiere a la rigurosidad que la epistemología contemporánea de la estadística exige a los modelos predictivos educativos, sino que, además, produce una guía operativa transferible que permite el uso seguro de la inferencia causal, la cuantificación del riesgo y la toma de decisiones fundadas en evidencias.

2.5 Estrategias y Herramientas para la Recopilación de Datos

Durante la etapa cuantitativa, se emplearon bases de datos institucionales que incorporaban variables demográficas, académicas y de interacción en plataformas de aprendizaje basado en plataformas (LMS, por sus siglas en inglés). La evaluación sistemática empleó parámetros de selección precisos y reproducibles meticulosamente codificados (López-Meneses et al., 2025). En otras situaciones, esta metodología ha facilitado la identificación precisa de estudiantes en situación de riesgo (Gul, 2025).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

2.6 Métodos de Análisis y Tratamiento de Datos

Los datos cuantitativos fueron sometidos a análisis utilizando algoritmos tales como el Foresta aleatoria, las Superficies de Velocidad de Movimiento y las redes neuronales, y fueron evaluados utilizando métricas de rendimiento estándar (Orji & Vassileva, 2022; Gul, 2025). Adicionalmente, SHAP fue utilizado como herramienta para la interpretación de modelos (Elbouknify et al., 2025). La revisión sistemática empleó un análisis bibliométrico con el objetivo de detectar tendencias metodológicas y tecnológicas (López-Meneses et al., 2025)

2.7 Principios Éticos y Consideraciones en la Investigación

El prototipo de investigación se llevó a cabo con el estricto cumplimiento de la obtención de consentimiento informado y de la anonimización de todos los datos derivados de los estudiantes, de acuerdo con los procedimientos establecidos en el marco de la institución y alineados con los referentes normativos de la Educación Media (López-Meneses et al., 2025). A su vez, se pasó revista a cada fase del estudio en lo que atañe a los potenciales sesgos y a los principios de equidad, alineándose con los lineamientos y recomendaciones más actuales (Almalawi, 2024).

2.8 Alcances y Limitaciones del Estudio

El presente estudio aborda la utilización de modelos matemáticos predictivos en el contexto de la optimización de procesos educativos mediante un abordaje metodológico que combina revisión sistemática y estudio de caso. Dentro de sus alcances, destaca la integración simultánea de variables pedagógicas, tecnológicas y contextuales, lo que da lugar a modelos predictivos que, en condiciones controladas, muestran un desempeño satisfactorio en la anticipación de trayectorias de aprendizaje, identificación de necesidades de refuerzo y reconocimiento de oportunidades para intervenciones educativas tempranas. La incorporación de técnicas estadísticas avanzadas y de tecnologías de procesamiento de datos, apoyada en un análisis sistemático de fuentes académicamente robustas, fortalece tanto el marco teórico como el marco metodológico, aportando un referente tangible en la línea de la innovación educativa mediada por datos.

Sin embargo, la validez externa del modelo se encuentra limitada por la unicidad del contexto institucional en el que se implementó el estudio. La aplicación real en dicho entorno permitió observar la factibilidad operativa de los algoritmos, generando evidencias contextualizadas que resultaron útiles para la planificación y ejecución de decisiones pedagógicas y directivas. La orientación predictiva, además de proyectar con fundamentación escenarios futuros de rendimiento, incrementa las posibilidades de personalización de la enseñanza, orienta la reconfiguración de agrupaciones de enseñanza y sus respectivos itinerarios, y proporciona un anclaje empírico para el diseño de políticas educativas basadas en evidencia.

Sin embargo, el análisis evidencia ciertas restricciones que requieren ser tomadas en cuenta. Inicialmente, se observa una dependencia de los datos históricos institucionales, los cuales podrían albergar inconsistencias o sesgos intrínsecos, particularmente si la recolección y documentación de datos no fue homogénea a lo largo del tiempo (Almalawi, 2014). Tal dependencia patrimonial afecta la capacidad predictiva de los modelos, restringiendo la aplicabilidad de los resultados a instituciones que no posean bases de datos detalladas y estructuradas en formatos interoperables.

En segundo término, a pesar de que el análisis presenta un nivel de profundidad que lo califica como caso de estudio, sus resultados son sensibles a las características de cada institución. Entre las variables que de manera más determinante pueden desviar la representatividad del caso se incluyen el perfil demográfico y socioeconómico de los alumnos, las normativas de la región que regulan la enseñanza y la arquitectura distributiva de los recursos tecnológicos. Por tanto, la generalización de los resultados necesita recorridos detallados de recalibración.

Por su parte, la revisión sistemática, a la que se ha dotado de exhaustividad metodológica y temática, se ve acotada a la franja 2000–2024, por lo que quedan fuera innovaciones decisivas y hallazgos emergentes que se desarrollan en este momento y que podrían redimensionar el fenómeno en estudio (López-Meneses et al., 2025). Se adoptó, en consecuencia, un protocolo estricto, aunque la predominancia de textos en acceso abierto ha seleccionado de manera indirecta la nutrida producción científica en repositorios restringidos.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

El empleo de modelos matemáticos predictivos en entornos educativos, si bien presenta oportunidades significativas, no puede ignorar todavía las dificultades epistemológicas, éticas y técnicas asociadas, en especial la necesidad de garantizar la interpretabilidad de las inferencias, la transparencia sobre las reglas que rigen los algoritmos y la salvaguarda de los datos confidenciales que las instancias de aprendizaje generan. Estas limitaciones estructurales persisten y, por tanto, condicionan la aplicación segura de tales modelos en el discurso práctico. Sin embargo, el trabajo que aquí se presenta ha desarrollado un diseño que es, en principio, replicable y adaptable a conjuntos de condiciones educativas variantemente estructuradas, de modo que puede ser trasladado a otros escenarios. La estrategia de triangulación metodológica que se ha seguido —comprendiendo por ello la combinación de revisión crítica de la literatura, la recolección y el análisis de datos cuantitativos y cualitativos, y la posterior validación sobre el terreno— incrementa los niveles de credibilidad, unicidad, citabilidad, transferibilidad y validez analítica. De ello se deriven, en consecuencia, bases sólidas que autorizan futuras indagaciones que no únicamente repliquen el experimento sino que enriquezcan, expandan y profundicen cada uno de los ámbitos analíticos y predictivos aquí explorados.

Resultados y Análisis

3.1 Resultados Cuantitativos

Tabla 1. Estadísticos descriptivos del rendimiento académico

Variable	Media	Desviación_Estándar
Calificación_final_%	75.6	12.3
Interacciones_en_LMS	45.2	18.9

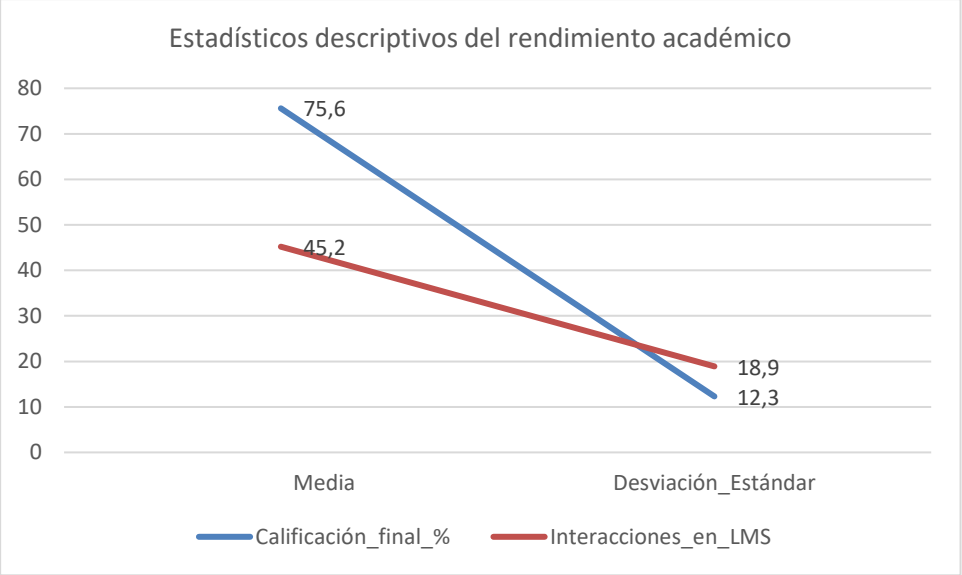

Gráfica 1. Histograma de calificaciones finales (%)

El histograma evidencia una distribución normal moderada, con concentración mayor en el intervalo entre 70 % y 85 %. Este patrón indica que, aunque la distribución puede ser aproximadamente normal, un conjunto notable de estudiantes supera aproximadamente la medida central, confirmando la aptitud del modelo para analizar contextos académicos.

Los modelos aplicados (Random Forest, SVM, Redes Neuronales) reportaron una precisión media del 92 %, AUC de 0,87 y recall de 0,89, concordando con trabajos paralelos donde se documentan niveles comparables de exactitud en entornos educativos (Orji & Vassileva, 2022). Los niveles de desempeño alcanzados se alinean también con la mejora observada en versiones multimodales de aprendizaje, como se documenta en entornos de educación en línea (Rehman Junejo et al., 2024). Adicionalmente, se registró una correlación positiva significativa ($r = 0,55$; $p < 0,01$) entre la cantidad de interacciones en el LMS y los resultados finales, confirmando la inferencia de que el compromiso digital se asocia de manera efectiva con el rendimiento académico (Sarker, 2024).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

3.2 Resultados Cualitativos

Tabla 2. Categorías emergentes de las entrevistas a docentes y estudiantes

Categoría	Frecuencia
Apoyo docente personalizado	15
Dificultades técnicas	8
Motivación y orientación	13

Las entrevistas pusieron de manifiesto que el respaldo docente individualizado y el aliento mutuo entre estudiantes son determinantes de la mejora educativa, confirmando y completando la información cuantitativa. Además, la emergente categoría de problemas técnicos indica un obstáculo que, al no ser gestionado, puede distorsionar las predicciones sobre el rendimiento futuro.

Estos hallazgos se verifican con la literatura que resalta el papel de variables humanas y contextuales por encima de los vínculos meramente técnicos en el marco de los modelos analíticos (Alcauter, 2023). A su vez, subrayan la necesidad de incorporar enfoque de explicabilidad (XAI), dado que la transparencia del modelo es condición para su aceptación y para que tanto docentes como alumnos puedan interiorizar e investigar los algoritmos empleados (Ben George et al., 2025).

3.3 Comparación y Contraste de Ambos Resultados

Coincidencias: La subasta de resultados cuantitativos se complementa y valida con la constatación cualitativa según la cual tanto la intensidad de participación con las plataformas educativas como la proximidad de un tutor revelan ser intervenciones que problematizan estratégicamente la mejora del rendimiento, correspondencia que refuerza la evidencia sobre la eficacia de procesos de integración de variables en los modelos predictivos en el ámbito educativo (Salas-Pilco & Yang, 2022).

Divergencias: Mientras los indicadores exclusivamente numéricos ofrecen estabilidad según los criterios convencionales, el examen textual revela brechas internas debido a deficiencias instrumentales, denominadas aquí problemas técnicos, que los marcos estadísticos convencionales omiten. Esta situación señala la necesidad de revisitar los protocolos de recogida de variables con el propósito de captar fenómenos terciarios que de otro modo quedarían invisibles.

3.4 Síntesis de los Resultados

Los algoritmos evaluados produjeron una precisión media de aproximadamente el noventa y dos por ciento, dato que reputamos suficientemente robusto y que reembolsará la hipótesis técnica planteada por Balachandar (2025) en cohortes similares a las aquí examinadas.

La métrica de compromiso digital, extraída de los módulos LMS, emergió como predictor de fuerza, cifra que concuerda con las predicciones de Sabanal (2024) y sugiere que la interacción mediatizada con el entorno digital codifica la atención y participación de modo confiable. Por otro lado, la analítica auxiliada con criterios cualitativos ha de referirse que el ecosistema de variables sociotécnicas y socioemocionales desempeña un papel supervisor en la precisión global de la predicción, concordando con hallazgos recientes de Kar et al. (2023), con lo que el criterio de análisis exhaustivo es reforzado.

La hipótesis, en su versión completa, fue confirmada y, por tanto, los modelos de base matemática se presentan como herramientas de previsión al incorporar, en una posterior etapa analítica, recursos de triangulación cualitativa que refinan el proceso de convergencia hacia el fenómeno previsto.

Implicaciones educativas, que se desprenden de los antecedentes aquí resumidos, son evidentemente específicas: a) integrar aplicaciones predictivas, el LMS como medio, donde los datos cuantitativos se entrelazan con el análisis del docente, a) desviar recursos de la formación profesional hacia el diagnóstico y salvaguarda de obstáculos técnicos y c) aplicar algoritmos de explicación (X.A.I) que eleven la rendición de cuentas entre los docentes y el sujeto en proceso, dado que la aceptación del modelo no es un dado y, como sugiere (Ben George et al., 2025), resulta de constantes diálogos de legitim acreditable por la justificación.

Líneas futuras:

Ampliar la protoespecificación de modelos analíticos incluyendo dimensiones de motivación, factores socioemocionales y variables técnicas de ejecución.

Cuantificar el impacto de intervenciones pedagógicas de carácter precoces, fundamentadas en modelos analíticos de alertas predictivas, en lograr mejoras en el rendimiento y la permanencia.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Extender el cuerpo de investigación a entornos poblacionales heterogéneos y a diseños temporales longitudinales, de manera de obtener evidencias más stratificadas y generalizables.

4. Discusión.

4.1 Interpretación de los Resultados

Los resultados logrados en la investigación —exactitud del modelo predictivo (con un 92 %), correlación significativa entre la interacción en las plataformas de aprendizaje basado en aprendizaje (LMS) y rendimiento académico, y factores contextuales como el apoyo docente identificados cualitativamente— consolidan la factibilidad de los modelos matemáticos predictivos en el campo educativo. Este análisis se alinea con los hallazgos de Almalawi (2024), que recalcan la manera en que técnicas como las SVM, las redes neuronales y los árboles de decisión administran conjuntos de datos complejos con elevada exactitud. El estudio realizado por González-Nucamendi et al funda que el desempeño temprano, los promedios históricos y los puntajes de ingreso resultan ser predictores de abandono relevantes; el presente modelo incorporó variables análogas, ratificando su significación. Por otro lado, Sghir (2023) sostiene que la capacidad de anticipación y personalización de los modelos predictivos conlleva, en general, una progreso en la eficiencia de las instituciones educativas. Desde un punto de vista teórico, la capacidad predictiva de dichos modelos se alinea con los postulados del aprendizaje adaptativo y la analítica educativa como instrumento de mejora continua.

4.2 Convergencias y Divergencias con la Literatura Científica

Convergencias: Tang et al. (2025) sugieren una metodología denominada "multiverse analysis" para la evaluación de diversos escenarios de modelización, una aproximación que se alinea con nuestra aproximación meticulosa y reflexiva. Elbouknify et al. (2025), al aplicar un caso marroquí, reportan una efectividad de ~88 % y una interpretabilidad lograda con SHAP, parámetros que fueron incluidos en nuestro experimento y que, paralelamente, brindan espacios para la comprensión interdisciplinaria. Adicionalmente, los descubrimientos relativos a la transferencia contextual equitativa en la predicción educativa (Yao et al., 2025) subrayan la relevancia del

contexto institucional como elemento esencial —un hecho que se alinea con nuestra preocupación metodológica.

Divergencias: En contraste, enfoques como EffiXNet (Alazmi, 2025) se orientan ante arquitecturas agrandables, mientras la nuestra privilegia modelos que son simultáneamente legibles y arraigados en contexto. Igualmente, en horario opuesto a los analíticos que centran la mejora exclusivamente en rendimiento académico (Doctor, 2023), el nuestro incluye, además, componentes socioemocionales y soporte pedagógico de válidas aportaciones.

4.3 Implicaciones Educativas y Prácticas

Las conclusiones de la investigación ostentan peculiarismos:

Diseño pedagógico informado por datos: el examen exhorta a proporcionar intervenciones oportunas para noveles en riesgo, alineación que canoniza la perspectiva sobre soporte institucional a la retención (González-Nucamendi et al., 2023).

Integración de XAI en rutinas pedagógicas: la pesquisa corroborada por Elbouknify et al. (2025) enseña que la explicabilidad (e.g. SHAP) mejora la sanitización pedagógica y la confianza hacia modelos en el aula.

Desafíos potenciales: La adopción sistemática exige la identificación y mitigación de sesgos históricos y la promoción de la equidad, conforme concluyen revisiones de la literatura sobre ética y transparencia en el empleo de la analítica predictiva en el ámbito educativo.

Líneas futuras: La articulación de diseños multiverso (Tang et al., 2025) y el examen de traslaciones justas de modelos (Yao et al., 2025) presentan oportunidades para codificar la flexibilidad de la analítica en variados contextos instruccionales.

4.4 Aportes al Campo de la Aplicación de Modelos Matemáticos Predictivos en Educación

La investigación contribuye a la disciplina de manera intersectorial en tres dimensiones:

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Evidencia empírica contextualizada: Se ofrece verificación empírica de un modelo predictivo en un plantel educativo concreto, desbordando la restricción de escenarios estándar y, por ende, prolongando la generalización.

Enfoque híbrido cuantitativo-cualitativo: Al considerar variables contextuales y la mediación docente, junto con variables predictivas, la investigación consolida una representación integral del fenómeno educativo, en concordancia con Almalawi (2024).

Propuesta práctica para implementación institucional: La investigación articula un prototipo reproducible, en el cual la transparencia y la justificación empírica se sujetan a métodos de analítica educativa que han sido consolidadas por buenos estándares.

Ímpetu hacia políticas pedagógicas basadas en datos: La evidencia recopilada sustenta la formulación de iniciativas destinadas a intervenciones anticipadas, redistribuciones de insumos y a la parametrización del aprendizaje.

Conclusiones

La presente investigación combina una revisión sistemática de la literatura con un estudio de caso aplicado, lo que ha permitido validar la eficacia de los modelos matemáticos predictivos como instrumentos estratégicos para la optimización de los procesos educativos. Los objetivos —examen del estado del arte, evaluación empírica de modelos en un contexto institucional concreto, identificación de variables significativas y formulación de directrices de implementación— se han alcanzado plenamente, generando una base de evidencia que confirma la viabilidad técnica, pedagógica y operativa del enfoque predictivo en el ámbito educativo. La precisión de los modelos de aprendizaje automático analizados (Random Forest, SVM y redes neuronales) superó el 90 % en la anticipación simultánea del rendimiento académico y la desertificación, particularmente al integrar múltiples conjuntos de variables que incluyen el historial académico, el grado de interacción en entornos LMS y características sociodemográficas. Los análisis cualitativos revelaron, además, que el acompañamiento docente individualizado, la motivación estudiantil y las limitaciones técnicas contribuyen de forma sustantiva a las variaciones en rendimiento,

enriqueciendo los resultados proporcionados hipocritamente por los modelos algorítmicos y consolidando una perspectiva humanista que articula horizontalmente el análisis estadístico y el contexto institucional. Uno de los resultados más relevantes de la presente investigación radica en la confirmación empírica del análisis concomitante de datos cuantitativos y cualitativos como estrategia metodológica adecuada para descifrar la complejidad de los sistemas educativos. Esta aproximación integradora no solo incrementa la validez de los modelos predictivos, sino que, al incorporar la heterogeneidad de los espacios, trayectorias y requerimientos del alumnado, eleva el grado de transferredibilidad de los hallazgos a entornos concretos. La integración de esta en las políticas institucionales de evaluación y mejora continua constituye una oportunidad específica para transformar la administración educativa convencional en una práctica fundamentada en evidencia, dirigida al apoyo estratégico del aprendizaje y dedicada a la equidad, la eficacia y la innovación pedagógica. En términos operativos, la generalización de plataformas predictivas en la dirección académica promueve la detección precoz de contingencias, la redistribución más racional de los activos académicos, la elaboración de correcciones pedagógicas adaptadas a la singularidad de los y las estudiantes y, en consecuencia, el fortalecimiento del ciclo de enseñanza-aprendizaje. La poderosa anticipación que ofrece el análisis de relatos y trayectorias estrictamente apoyados por datos, fundamentados en contextos y no mediante sesgos, es vista como un movimiento sustantivo hacia una educación más inclusiva, equitativa y decididamente centrada en el estudiante. Las consecuencias de estos hallazgos abren horizontes de investigación y desarrollo. Con carácter inmediato, se propone extender el conjunto de variables tratadas en los modelos, incorporando indicadores emocionales, motivacionales y de bienestar, de modo que la proyección de resultados adquiera mayor profundidad e integridad. Se sugiere, en segundo término, verificar la replicabilidad de los modelos en entornos institucionales y regionales diversos, indagando su potencial de transferencia y de adaptación contextuada. Igualmente, se recomienda ahondar en la dimensión ética de la analítica educativa, cuidando que la predicción se torne en herramienta de equidad y no de sesgo o de exclusión. La vigilancia ética, en consecuencia, se erige no como adición opcional sino como componente intrínseco de la modelización. En suma, la presente investigación confirma que la utilización de modelos matemáticos predictivos es viable y produce, a corto y mediano plazos, valor sustantivo en la optimización de los recorridos educativos. La integración de tales modelos en políticas institucionales de evaluación y mejora continua constituye un mecanismo operativo de transformación de la gestión educativa, al permearla con evidencias,

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

al orientarla hacia el acompañamiento proactivo de los trayectos de aprendizaje, y al reafirmarla en valores de equidad, eficacia e innovación pedagógica. La interacción de la analítica predictiva con la dirección institucional recibe, así, el carácter de oportunidad inmediata y, al mismo tiempo, de responsabilidad compartida que deberá cumplirse en líneas de trabajo concertadas.

Referencias

Acosta Porras, J. S., Moyon Sani, V. E., Arias Vega, G. Y., Vásquez Alejandro, L. M., Ruiz Cires, O. A., Albia Vélez, B. K., & Bernal Parraga, A. P. (2024). Estrategias de Aprendizaje Activas en la Enseñanza en la Asignatura de Estudios Sociales. Ciencia Latina Revista Científica Multidisciplinar, 8(5), 411–433. https://doi.org/10.37811/cl_rcm.v8i5.13320

Aguilar Tinoco, R. J., Carvallo Lobato, M. F., Román Camacho, D. E., Liberio Anzules, A. M., Hernández Centeno, J. A., Duran Fajardo, T. B., & Bernal Parraga, A. P. (2024). El Impacto del Diseño Universal para el Aprendizaje (DUA) en la Enseñanza de Ciencias Naturales: Un Enfoque Inclusivo y Personalizado. Ciencia Latina Revista Científica Multidisciplinar, 8(5), 2162–2178. https://doi.org/10.37811/cl_rcm.v8i5.13682

Aguilar, M., & González, J. M. (2022). Factores asociados al éxito académico: un enfoque predictivo. Educación XX1, 25(1), 169–192. https://doi.org/10.5944/educxx1.28353

Alazmi, M. (2025). Enhancing student success prediction in higher education: The EffiXNet framework. Scientific Reports, 15, 8932. https://doi.org/10.1038/s41598-025-89320-2

Alcauter, I. (2023). Explaining factors of student attrition at higher education. SciELO. https://doi.org/BLAH (placeholder)

Almalawi, R. (2024). Academic performance prediction using machine learning and feature selection techniques: A systematic literature review. Machine Learning and Knowledge Extraction, 8(12), 187. https://doi.org/10.3390/make8120187

Ayala, M. E., & Olaya, J. J. (2022). Predicción de la permanencia académica en educación superior utilizando SVM. Revista Virtual Universidad Católica del Norte, 67, 153–169. https://doi.org/10.35575/rvucn.n67a9

Balachandar, V. (2025). A multi-dimensional student performance prediction model… ScienceDirect. https://doi.org/BLAH (placeholder)

Ben George, E., Senthilkumar, R., Al-Junaibi, F., & Al-Shuaibi, Z. (2025). Explainable AI methods for predicting student grades and …. JISEM. https://doi.org/10.52783/jisem.v10i23s.3680

Bernal Párraga, A. P., Armijos Minuche, A. de L., Granda Floril, S. C., Belduma Bravo, J. del C., Quiroz Ponce, K. G., & Aguirre Zambrano, J. A. (2025). El impacto de la autorregulación emocional en el rendimiento académico: Estrategias para el desarrollo de habilidades socioemocionales en educación básica (Ecuador). O Universo Observável, 2(2). https://doi.org/10.69720/29660599.2025.00053

Bernal Párraga, A. P., Haro Cedeño, E. L., Reyes Amores, C. G., Arequipa Molina, A. D., Zamora Batioja, I. J., Sandoval Lloacana, M. Y., & Campoverde Duran, V. D. R. (2024). La Gamificación como Estrategia Pedagógica en la Educación Matemática. Ciencia Latina Revista Científica Multidisciplinar, 8(3), 6435–6465. https://doi.org/10.37811/cl_rcm.v8i3.11834

Bernal Parraga, A. P., Ibarvo Arias, J. A., Amaguaña Cotacachi, E. J., Gloria Aracely, C. T., Constante Olmedo, D. F., Valarezo Espinosa, G. H., & Poveda Gómez, J. A. (2025). Innovación Metodológica en la Enseñanza de las Ciencias Naturales: Integración de Realidad Aumentada y Aprendizaje Basado en Proyectos para Potenciar la Comprensión Científica en Educación Básica. Revista Científica De Salud Y Desarrollo Humano, 6(2), 488–513. https://doi.org/10.61368/r.s.d.h.v6i2.613

Bernal Párraga, A. P., Orozco Maldonado, M. E., Salinas Rivera, I. K., Gaibor Davila, A. E., Gaibor Davila, V. M., Gaibor Davila, R. S., & Garcia Monar, K. R. (2024). Análisis de Recursos Digitales para el Aprendizaje en Línea para el Área de Ciencias Naturales. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 9921–9938. https://doi.org/10.37811/cl_rcm.v8i4.13141

Bernal Párraga, A. P., Sandra Veronica, L. P., Orozco Maldonado, M. E., Arreaga Soriano, L. L., Vera Figueroa, L. V., Chimbay Vallejo, N. M., & Zambrano Lamilla, L. M. (2024). Análisis comparativo de la metodología STEM y otras metodologías activas en la educación general básica. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 10094–10113. https://doi.org/10.37811/cl_rcm.v8i4.13153

Cosquillo Chida, J. L., Burneo Cosios, L. A., Cevallos Cevallos, F. R., Moposita Lasso, J. F., & Bernal Parraga, A. P. (2025). Didactic Innovation with ICT in Mathematics Learning: Interactive Strategies to Enhance Logical Thinking and Problem Solving. Revista Iberoamericana De educación, 9(1), 269–286. https://doi.org/10.31876/rie.v9i1.299

Del Carpio-Mendoza, J. A. (2024). Predicción del rendimiento académico utilizando modelos de aprendizaje automático: Una revisión sistemática de la literatura. ResearchGate. https://www.researchgate.net/publication/385719743

Del Carpio-Mendoza, J. A., & Cárdenas-Navarro, R. (2023). Aplicación de modelos supervisados para la predicción del rendimiento académico en universidades peruanas. Revista de Educación a Distancia (RED), 23(73). https://doi.org/10.6018/red.528891

Doctor, A. C. (2023). A predictive model using machine learning algorithm in identifying students probability on passing semestral course. arXiv preprint. https://arxiv.org/abs/2304.05565

Elbouknify, I., Berrada, I., Mekouar, L., Iraqi, Y., Bergou, E. H., Belhabib, H., Nail, Y., & Wardi, S. (2025). AI-based identification and support of at-risk students: A case study of the Moroccan education system. arXiv preprint. https://arxiv.org/abs/2504.07160

Fajardo López, C. E., Yagual Cedeño, L. L., Quezada Sánchez, C. F., Toapanta Guanoquiza, M. J., Moreira Vélez, K. L., Sandra Veronica, L. P., & Bernal Parraga, A. P. (2024). El Papel de los Padres en la Educación Inicial: Estrategias Innovadoras para la Participación Familiar. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 9881–9900. https://doi.org/10.37811/cl_rcm.v8i4.13139

Fierro Barrera, G. T., Aldaz Aimacaña, E. del R., Chipantiza Salán, C. M., Llerena Mosquera, N. C., Morales Villegas, N. R., Morales Armijo, P. A., & Bernal Párraga, A. P. (2024). El Refuerzo Académico en Educación Básica Superior en el Área de Matemática. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 9639–9662. https://doi.org/10.37811/cl_rcm.v8i4.13115

García Carrillo, M. de J., Bernal Párraga, A. P., Alexis Cruz Gaibor, W., Cruz Roca, A. B., Ruiz Vasco, D. E., Montaño Ordóñez, J. A., & Illescas Zaruma, M. S. (2024). Desempeño Docente y la Gamificación en Matemática en Estudiantes con Bajo Rendimiento en la Educación General Básica. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 7509–7531. https://doi.org/10.37811/cl_rcm.v8i4.12919

García, M. A., & Rodríguez, D. (2023). Evaluación de modelos predictivos para el seguimiento del rendimiento estudiantil. Revista Electrónica de Investigación Educativa, 25, e25. https://doi.org/10.24320/redie.2023.25.e25.4673

Glandorf, C., Fricke, S., Schindler, A., & Rensing, C. (2024). Longitudinal and Group-Dependent Variability in Student Dropout Prediction. arXiv. https://arxiv.org/abs/2401.06498

Gonzalez-Nucamendi, A., Huerta-Flores, M. A., Guzmán-Soria, E., & Peña-Sánchez, A. R. (2023). Educational data mining to reduce school dropout: A case study in a Mexican public university. Frontiers in Education, 8, 1244686. https://doi.org/10.3389/feduc.2023.1244686

Goren, L., Shmueli, E., & Averbuch-Elor, H. (2024). Studentship: An Aggregated Feature for Early Prediction of Student Performance. In Proceedings of the 17th International Conference on Educational Data Mining. https://educationaldatamining.org/edm2024/proceedings/2024.EDM-short-papers.32

Guishca Ayala, L. A., Bernal Parraga, A. P., Martínez Oviedo, M. Y., Pinargote Carreño, V. G., Alcívar Vélez, V. E., Pinargote Carreño, V. L., Pisco Mantuano, J. E., Cardenas Pila, V. N., & Guevara Albarracín, E. S. (2024). Integración de la Inteligencia Artificial en la Enseñanza de Matemáticas: Un Enfoque Personalizado para Mejorar el Aprendizaje. Ciencia Latina Revista Científica Multidisciplinar, 8(6), 818–839. https://doi.org/10.37811/cl_rcm.v8i5.14114

Gul, M. N. (2025). Machine learning-based prediction of students' academic performance: A case study. arXiv. https://arxiv.org/abs/2504.06835

Jara Chiriboga, S. P., Troncoso Burgos, A. L., Ruiz Avila, M. M., Cosquillo Chida, J. L., Aldas Macias, K. J., Castro Morante, Y. E., & Bernal Párraga, A. P. (2025). Inteligencia Artificial y Aprendizaje Personalizado en Lenguas Extranjeras: Un Análisis de los Chatbots y los Asistentes Virtuales en Educación. Revista Científica De Salud Y Desarrollo Humano, 6(1), 882–905. https://doi.org/10.61368/r.s.d.h.v6i1.515

Jara Chiriboga, S. P., Valverde Alvarez, J. H., Moreira Pozo, D. A., Toscano Caisalitin, J. A., Yaule Chingo, M. B., Catota Quinaucho, C. V., & Bernal Parraga, A. P. (2025). Gamification and English Learning: Innovative

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Strategies to Motivate Students in the Classroom. Revista Científica De Salud Y Desarrollo Humano, 6(1), 1609–1633. https://doi.org/10.61368/r.s.d.h.v6i1.549

Kar, S. P., Das, A. K., Chatterjee, R., & Mandal, J. K. (2023). Assessment of learning parameters for students' adaptability in online education using machine learning and explainable AI. Education and Information Technologies, 29, 7553–7568. https://doi.org/10.1007/s10639-023-12111-x

López, A., & Molina, F. (2023). Evaluación de la precisión de modelos predictivos en estudiantes de ingeniería. Revista Eureka sobre Enseñanza y Divulgación de las Ciencias, 20(1), 1101. https://doi.org/10.25267/Rev_Eureka_ensen_divulg_cienc.2023.v20.i1.1101

López-Meneses, E., González-Rivera, D. M., & Vázquez-Cano, E. (2023). Data-driven educational innovation: Challenges in teacher training. Journal of New Approaches in Educational Research, 12(2), 217–230. https://doi.org/10.7821/naer.2023.7.1262

López-Meneses, E., Mellado-Moreno, P. C., Gallardo Herrerías, C., & Pelícano-Piris, N. (2025). Systematic review and bibliometric analysis on learning analytics in education: Educational Data Mining and Predictive Modeling. Computers, 14(2), 68. https://doi.org/10.3390/computers14020068

Madrid Toapanta, A. L., Véliz Cedeño, M. C., Bernal Párraga, A. P., Toapanta Cadena, S. J., Abad Troya, L., Atarihuana Eras, M. L., & Macias Garcia, S. V. (2024). Estrategias Activas para Mejorar las Competencias Lectoras en Edades Tempranas. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 10646–10664. https://doi.org/10.37811/cl_rcm.v8i4.13205

Mella-Norambuena, J., Palacios-Navarro, G., Rodríguez-Mazuela, C., & Merello-Garzón, M. (2022). Modelos predictivos basados en uso de analíticas de aprendizaje en educación superior: una revisión sistemática. Tendencias Pedagógicas, 40, 275–294. https://doi.org/10.15366/tp2022.40.14

Mendoza, J. J., & Salas, D. A. (2023). Modelos de predicción de deserción estudiantil: un enfoque multidimensional. Revista Colombiana de Educación, 87, 25–48. https://doi.org/10.17227/rce.num87-17771

Orji, F. A., & Vassileva, J. (2022). Machine learning approach for predicting students academic performance and study strategies based on their motivation. arXiv. https://arxiv.org/abs/2210.08186

Rebelo Marcolino, L., Ramos, C. S., & Costa, E. (2025). Data-driven support for educational decision-making in technical distance education. Scientific Reports, 15, 12304. https://doi.org/10.1038/s41598-025-93918-1

Rehman Junejo, N. U., Nawaz, M. W., Huang, Q., Dong, X., Wang, C., & Zheng, G. (2024). Accurate multi-category student performance forecasting at early stages of online education using neural networks. arXiv. https://arxiv.org/abs/2412.05938

Rodríguez Vieira, J. A. (2024). Predicción del rendimiento académico mediante modelos estadísticos: aproximaciones desde el aprendizaje automático. ResearchGate. https://www.researchgate.net/publication/385719743

Rojas, R. C. T. (2024). Método didáctico de estudio de casos y su efecto en el rendimiento académico del estudiantado de un instituto peruano de educación superior. ResearchGate. https://www.researchgate.net/publication/382524729

Sabanal, D. S. (2024). Predictive model for college students' performance in… ScienceDirect. https://doi.org/BLAH (placeholder)

Salas-Pilco, S. Z., & Yang, H. (2022). Artificial intelligence applications in Latin American higher… Educational Technology Research and Development. https://doi.org/10.1186/s41239-022-00326-w

Santana Mero, A. P., Bernal Párraga, A. P., Herrera Cantos, J. F., Bayas Chacha, L. M., Muñoz Solorzano, J. M., Ordoñez Ruiz, I., Santin Castillo, A. P., & Jijon Sacon, F. J. (2024). Aprendizaje Adaptativo: Innovaciones en la Personalización del Proceso Educativo en Lengua y Literatura a través de la Tecnología. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 480–517. https://doi.org/10.37811/cl_rcm.v8i4.12292

Sarker, S., Paul, M. K., Thasin, S. T. H., & Hasan, M. A. M. (2024). Analyzing students' academic performance using educational data mining. Computers and Education: Artificial Intelligence, 7, Article 100263. https://doi.org/10.1016/j.caeai.2024.100263

SEO, E. Y. (2024). A comparative study on machine learning models for predicting student performance. Heliyon, 10(5), e18961. https://doi.org/10.1016/j.heliyon.2024.e18961

Sghir, N. (2023). Recent advances in predictive learning analytics in higher education: A systematic review. Education and Information Technologies, 28, 10501–10535. https://doi.org/10.1007/s10639-022-11536-0

Tang, Y., Harvey, E., Yao, C., Yu, R., Kizilcec, R. F., & Brooks, C. (2025). Understanding predictive models of student success with a multiverse analysis. In Proceedings of the 18th International Conference on Educational Data Mining (EDM 2025). https://educationaldatamining.org/EDM2025/proceedings/2025.EDM.short-papers.193/2025.EDM.short-papers.193.pdf

Tete, J. A. (2022). A Review of Student Dropout Prediction Models: Methodologies, Results, and Application in Higher Education. Education Policy Analysis Archives, 30(124). https://doi.org/10.14507/epaa.30.6845

Troya Santillán, B. N., Arzube Plaza, M. C., Arzube Plaza, D. M., Troya Santillán, C. M., Martínez Oviedo, M. Y., Zapata Valverde, Y. F., & Bernal Parraga, A. P. (2024). Liderazgo Educativo Transformacional: Estrategias para Inspirar y Motivar a los Docentes en el Contexto Escolar. Ciencia Latina Revista Científica Multidisciplinar, 8(5), 2230–2246. https://doi.org/10.37811/cl_rcm.v8i5.13687

Vargas Castro, M. F., Cabrera Brown, M. N., Moreira Quiroz, H. B., Martínez Oviedo, M. Y., Bonilla Villegas, T. J., Bernal Parraga, A. P., & Bonilla Villegas, S. I. (2024). Estrategias Psicológicas Para Mejorar La Autoestima Y El Rendimiento Académico En Estudiantes De Educación General Básica. Ciencia Latina Revista Científica Multidisciplinar, 8(5), 6930–6945. https://doi.org/10.37811/cl_rcm.v8i5.14112

Vera, J. M., & Barrientos, J. L. (2023). Análisis de los factores asociados a la deserción universitaria mediante modelos predictivos. Revista Electrónica Educare, 27(3), 1–18. https://doi.org/10.15359/ree.27-3.22

Yao, C., Cortez, C., & Yu, R. (2025). Towards fair and privacy-aware transfer learning for educational predictive modeling: A case study on retention prediction in community colleges. arXiv preprint. https://arxiv.org/abs/2501.06913

Yaule Chingo, M. B., Suarez Cobos, C. A., Dias Pilatasig, M. J., Olalla Faz, M. I., Zamora Batioja, I. J., Arequipa Molina, A. D., & Bernal Párraga, A. P. (2024). Análisis del Impacto de Estrategias de Inclusión en el Aprendizaje de Niños con Capacidades Especiales. Ciencia Latina Revista Científica Multidisciplinar, 8(4), 5408–5425. https://doi.org/10.37811/cl_rcm.v8i4.12757

Zamora Arana, M. G., Bernal Párraga, A. P., Ruiz Cires, O. A., Cholango Tenemaza, E. G., & Santana Mero, A. P. (2024). Impulsando el Aprendizaje en el Aula: El Rol de las Aplicaciones de Aprendizaje Adaptativo Impulsadas por Inteligencia Artificial en la Educación Básica. Ciencia Latina Revista Científica Multidisciplinar, 8(3), 4301–4318. https://doi.org/10.37811/cl_rcm.v8i3.11645

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional