



Modelo de aprendizaje adaptativo con inteligencia artificial para mejorar rendimiento académico en universitarios ecuatorianos

Adaptive learning model with artificial intelligence to improve academic performance among Ecuadorian university students

Vivian Ruth Cabezas-Pesantes
vivian.cabezas@iess.gob.ec

Red de investigación Koinonía, Portoviejo, Manabí, Ecuador
<https://orcid.org/0009-0006-2385-3964>

María Beatriz Yuquilema-Cortez
myuquilemac@unemi.edu.ec

Universidad Estatal de Milagro, Milagros, Guayas, Ecuador
<https://orcid.org/0000-0003-2196-1954>

María Agustina León-Miski
maria-leon2009@hotmail.com

Red de investigación Koinonía, Portoviejo, Manabí, Ecuador
<https://orcid.org/0009-0004-3302-2588>

Amanda Abigail Villafuerte-Fernández
avillafuertef@unemi.edu.ec

Universidad Estatal de Milagro, Milagros, Guayas, Ecuador
<https://orcid.org/0000-0003-3541-6957>

RESUMEN

La transformación digital en educación superior latinoamericana enfrenta desafíos vinculados con masificación educativa, diversificación estudiantil y restricciones presupuestarias, demandando alternativas tecnológicas que potencien procesos formativos sin comprometer equidad institucional. La investigación tiene por objetivo diseñar un modelo de aprendizaje adaptativo con inteligencia artificial para mejorar el rendimiento académico en universitarios ecuatorianos. Se empleó un diseño descriptivo documental mediante análisis sistemático de dieciséis referencias bibliográficas publicadas entre 2022-2025, seleccionadas por pertinencia temática y rigor metodológico, aplicando análisis categorial en cuatro fases secuenciales. Los resultados evidenciaron consenso conceptual sobre sistemas adaptativos y beneficios en retención estudiantil. Se diseñó un modelo contextualizado que integra cinco componentes interrelacionados: sistema de diagnóstico integral multidominio, motor algorítmico de personalización pedagógica, repositorio modular de contenidos adaptativos, sistema de retroalimentación inmediata y módulo de evaluación continua con analítica predictiva. La propuesta ofrece un marco tecnopedagógico adaptable a particularidades ecuatorianas, requiriendo validación empírica mediante estudios de implementación.

Descriptor: inteligencia artificial; enseñanza superior; tecnología educacional. (Fuente: Tesoro UNESCO).

ABSTRACT

Digital transformation in Latin American higher education faces challenges related to educational massification, student diversification, and budgetary constraints, demanding technological alternatives that enhance educational processes without compromising institutional equity. The research aims to design an adaptive learning model with artificial intelligence to improve academic performance among Ecuadorian university students. A descriptive documentary design was used through systematic analysis of sixteen bibliographic references published between 2022 and 2025, selected for their thematic relevance and methodological rigour, applying categorical analysis in four sequential phases. The results showed conceptual consensus on adaptive systems and benefits in student retention. A contextualised model was designed that integrates five interrelated components: a comprehensive multi-domain diagnostic system, an algorithmic engine for pedagogical personalisation, a modular repository of adaptive content, an immediate feedback system, and a continuous assessment module with predictive analytics. The proposal offers a techno-pedagogical framework adaptable to Ecuadorian particularities, requiring empirical validation through implementation studies.

Descriptors: artificial intelligence; higher education; educational technology. (Source: UNESCO Thesaurus).

Recibido: 13/10/2025. Revisado: 18/10/2025. Aprobado: 30/10/2025. Publicado: 22/11/2025.

Sección artículos de investigación



INTRODUCCIÓN

Es consecuente tener en consideración que la transformación digital en la educación superior latinoamericana enfrenta desafíos estructurales que demandan respuestas innovadoras y contextualizadas. En Ecuador, las universidades atraviesan un proceso de reconfiguración pedagógica donde convergen exigencias de calidad académica, diversificación estudiantil y restricciones presupuestarias que limitan la atención personalizada; esta tensión entre masificación educativa y diferenciación curricular configura un escenario propicio para explorar alternativas tecnológicas que potencien los procesos formativos sin comprometer la equidad ni la pertinencia institucional.

Dentro de este panorama, la inteligencia artificial emerge como un campo tecnológico con aplicaciones prometedoras en contextos educativos, tal como plantean Bernik et al. (2025), los sistemas computacionales dotados de capacidades de procesamiento avanzado permiten automatizar tareas evaluativas, personalizar secuencias didácticas y generar analíticas predictivas sobre trayectorias académicas. Estas funcionalidades trascienden la mera incorporación instrumental de tecnología para configurar ecosistemas de aprendizaje donde las variables individuales del estudiante interactúan con arquitecturas algorítmicas capaces de ajustar dinámicamente contenidos, ritmos y estrategias pedagógicas.

Las investigaciones sobre aprendizaje adaptativo revelan transformaciones sustantivas en la relación pedagógica tradicional; en palabras de Aparicio-Gómez y Aparicio-Gómez (2024), los sistemas adaptativos redefinen los roles docentes al trasladar parte de las funciones instruccionales hacia plataformas inteligentes que monitorizan, diagnostican y prescriben acciones formativas diferenciadas. Esta redistribución de responsabilidades educativas no implica la sustitución del profesorado, sino la reconfiguración de sus competencias profesionales hacia dimensiones de acompañamiento, tutoría especializada y diseño curricular estratégico.

En el contexto ecuatoriano, diversos estudios documentan problemáticas vinculadas al rendimiento académico universitario, conforme señalan Almache-Sanisaca et al. (2025), las instituciones de educación superior del país evidencian tasas de deserción que oscilan entre el 22% y el 35% durante los dos primeros años de formación, asociadas principalmente a desajustes entre capacidades previas del estudiantado y exigencias curriculares de los programas. Asimismo, las brechas en competencias básicas de razonamiento lógico, comprensión lectora y pensamiento crítico se manifiestan como limitantes estructurales que condicionan las posibilidades de éxito académico en distintas áreas disciplinares.

De ese modo; Ma et al. (2014) reportan que los sistemas tutores inteligentes generan incrementos promedio de 0.42 desviaciones estándar en resultados de aprendizaje comparados con metodologías convencionales, con efectos particularmente significativos en disciplinas de ciencias exactas y áreas procedimentales, este resultado sugiere que las tecnologías adaptativas poseen potencial para incidir positivamente en trayectorias formativas, especialmente cuando se diseñan considerando perfiles estudiantiles específicos y objetivos curriculares bien definidos. No obstante, la transferencia acrítica de modelos tecnológicos desarrollados en otros contextos presenta limitaciones evidentes, en este orden, es necesario tener en cuenta que Fajardo-Aguilar et al. (2023), comentan que las condiciones infraestructurales, culturales y pedagógicas de las universidades ecuatorianas difieren sustancialmente de aquellas presentes en instituciones de Norteamérica, Europa o Asia donde se han implementado mayoritariamente estas innovaciones. En este sentido; las restricciones de conectividad, la heterogeneidad en alfabetización digital del profesorado y las resistencias institucionales ante cambios metodológicos constituyen variables contextuales que condicionan la viabilidad y sostenibilidad de cualquier propuesta tecnopedagógica.

Ante este panorama, resulta imprescindible desarrollar propuestas que articulen rigurosidad conceptual con factibilidad operativa, de ese modo; el objetivo de esta investigación consiste en diseñar un modelo de aprendizaje adaptativo con inteligencia artificial para mejorar el rendimiento académico en universitarios ecuatorianos.



MÉTODO

Este trabajo es un documento descriptivo en el que se utilizó el enfoque descriptivo documental; para su diseño se dispuso un análisis sistemático de bibliografía en Aprendizaje Adaptativo e Inteligencia Artificial aplicada a la educación actual. El esquema metodológico trabajó en la interpretación de la literatura académica referenciada para obtener fundamentos teóricos para construir la propuesta presentada la sección resultados.

La población de estudio estuvo constituida por 16 referencias bibliográficas publicadas entre 2022 y 2025, seleccionadas mediante criterios de pertinencia temática, rigor metodológico y relevancia académica. Los criterios de inclusión contemplaron: (a) publicaciones en revistas indexadas con revisión por pares, (b) abordaje específico de inteligencia artificial en educación superior, (c) disponibilidad de texto completo, y (d) idioma español o inglés. Se excluyeron documentos de divulgación general, textos sin sustento empírico y publicaciones anteriores a 2022 para garantizar la actualidad de los referentes teóricos.

El proceso de análisis de contenido se desarrolló en cuatro fases secuenciales. En primer lugar, se realizó una lectura exploratoria de cada documento para identificar ejes temáticos recurrentes y categorías emergentes relacionadas con sistemas adaptativos. Posteriormente, se ejecutó un análisis categorial donde se clasificaron los contenidos según dimensiones predefinidas: fundamentos teóricos, arquitecturas tecnológicas, resultados empíricos, metodologías de implementación y desafíos contextuales. La tercera fase contempló la construcción de matrices de análisis comparativo que permitieron identificar convergencias, divergencias y vacíos en la literatura revisada. En última instancia, se procedió a la síntesis interpretativa orientada al diseño del modelo de aprendizaje adaptativo contextualizado para universidades ecuatorianas.

El procedimiento de diseño del modelo siguió una lógica inductivo-deductiva donde los datos del análisis documental se integraron con principios pedagógicos fundamentales y consideraciones pragmáticas del contexto ecuatoriano. Se prestó especial atención a variables de viabilidad técnica, sostenibilidad financiera, aceptabilidad cultural y alineación con marcos normativos vigentes en el sistema de educación superior del país.

RESULTADOS

Resulta claro, mediante el análisis de literatura, el consenso conceptual en la naturaleza de los Aprendizajes Adaptativos, de acuerdo con lo expresado en los trabajos de Gligorea et al. (2023), se pueden definir estas estructuras según sus aptitudes para modificar dinámicamente parámetros instructivos, en función de los datos recopilados con respecto a los rendimientos, preferencias, y aptitudes individuales de cada alumno, con lo cual se superan enfoques diferenciales tradicionales en educación, dado el proceso de computacional masivo permitiendo durante el tiempo real y en escala institucional los ajustes necesarios.

La inteligencia artificial ofrece tres habilidades únicas a los entornos de aprendizaje adaptativo. Según lo expresa Ahmed et al. (2024), tales tecnologías permiten lo siguiente: (a) el pronóstico de trayectorias académicas mediante el uso de algoritmos de aprendizaje supervisado que detectan tempranamente patrones de riesgo o éxito, (b) el pronóstico de acciones educativas diferenciadas en función de perfiles de aprendizajes modelados estadísticamente, y (c) la automatización de procesos evaluativos que permiten al educador liberar tiempo para tareas de mayor complejidad cognitiva. Por lo tanto; la combinación de los tres propósitos define entonces una propuesta educativa donde la tecnología complementa, sino que potencia, las habilidades del educador.

De acuerdo con las investigaciones citadas, hay beneficios relacionados con la implementación de sistemas adaptativos; en su estudio de revisión sistemática Gutiérrez-Castillo et al. (2025), encuentran mejores medidas de retención de estudiantes, satisfacción con procesos de



desarrollo de estudiantes para lograr autonomía académica y metas de desarrollo de logros de aprendizaje. Éstas tienen efecto de manera más intensa cuando están implementadas de acuerdo con diseños curriculares institucionales y cuando este acompañamiento tiene un tratamiento asistido de manera crítica de sistemas curriculares, mostrando, así como la tecnología no tiene efecto sin un marco curricular.

Sin embargo, se señalan carencias y riesgos potenciales, Dave y Patel (2023), explican que los sistemas que funcionan con inteligencia artificial pueden perpetuar, mediante mecanismos de discriminación algorítmica, prejuicios que afecten a estudiantes que sean parte de algún perfil demográfico concreto, reproduciendo así desigualdades ya preestablecidas dentro del escenario educativo. Por otro lado, recoger innecesariamente grandes cantidades de datos con connotaciones individuales esconde cuestiones concernientes a los límites y principios de la privacidad, consentimiento informado y uso gubernamental o institucional.

Arquitecturas tecnológicas y componentes operativos

La evaluación de propuestas implementadas a escala internacional permite detectar factores arquitectónicos comunes a sistemas de aprendizaje adaptativo. Al continuar el desarrollo realizado por Wang (2025), para estos sistemas existe una integración entre los siguientes cinco módulos funcionales interconectados: (a) sistema de diagnóstico inicial para la evaluación del conocimiento previo, estilos de aprendizaje y aptitudes transversales; (b) motor de personalización algorítmica para el procesamiento de datos, que produce caminos de formato para el aprendizaje; (c) sistema de depósito de contenidos módulos clasificados por coeficiente de complejidad y dominio; (d) sistema de interfaz intuitivo para el aprendizaje, diseñado para la navegación guiada y seguimiento del progreso; (e) sistema de informes tanto de métricas cuantitativas como de seguimiento institucional del estudiante.

El motor de personalización es el corazón de estos sistemas, aunque el desarrollo de estos motores es una compleja tarea de investigación. Entendemos la elección de estos motores a través de una descripción proporcionada por Orji y Vassileva (2022), plantean que los algoritmos más efectivos combinan técnicas de aprendizaje automático supervisado como árboles de decisión, máquinas de vectores de soporte y redes neuronales con modelos probabilísticos que estiman las posibilidades de que los estudiantes dominen determinados contenidos. Estos algoritmos se nutren de datos históricos generados por estudiantes previos, identificando correlaciones entre diversos indicadores de interacción (duración de las sesiones de estudio, tipos de errores cometidos, secuencias de navegación) y los resultados de aprendizaje alcanzados. La precisión predictiva de estos sistemas se incrementa progresivamente conforme se acumula mayor volumen de información histórica (Orji y Vassileva, 2022).

Por otro lado, la calidad de la información educativa es un factor importante que condiciona la efectividad de estos sistemas; en consonancia con Cortez Granizo (2025) al abordar estos requisitos para los repositorios adaptativos, la preparación de materiales didácticos granulares es importante ya que deben tratarse de una formación innovadora concebida exclusivamente para facilitar la secuencialidad. Esta modalidad implica significativos desafíos en la producción académica. Otra característica esencial en cuanto a arquitectura del curso es el feedback. Según Gordon et al. (2024), los buenos sistemas de aprendizaje suministran respuestas inmediatas, específicas y útiles a los estudiantes para que puedan comprender sus errores en el área de los conocimientos, así como perfeccionar sus estrategias de estudio. El feedback supera a las meras puntuaciones que se otorgan a los estudiantes. Contiene información descriptiva, enunciando pasos procedimentales, remitiendo a recursos suplementarios y ofreciendo orientaciones metacognitivas que permiten al estudiante reflexionar sobre su proceso de aprendizaje y ajustar sus estrategias de estudio de manera autónoma y efectiva.



Experiencias empíricas y evidencias de efectividad

A partir de los registros en la literatura, existen numerosos estudios con resultados variados en cuanto a experiencias de implementación, en el contexto latinoamericano, Almache-Sanisaca, Rodríguez-Castro y Wang (2025) presentan una implementación llevada a cabo en tres universidades de Ecuador. Se implementó una plataforma adaptativa en los cursos básicos de matemáticas, cuyos resultados muestran incrementos del 18% en la tasa de aprobación, en comparación con secciones que emplearon metodología tradicional. Asimismo, los tiempos promedio requeridos para dominar los contenidos se redujeron en un 23% con respecto a las secciones precedentes, estos aportes resultaron estadísticamente significativos y consistentes a través de las tres instituciones participantes.

Las investigaciones sobre factores mediadores revelan que la efectividad de estos sistemas depende críticamente de variables contextuales, tal como plantean Bolaño-García y Duarte-Acosta (2024), las instituciones que logran mejores resultados comparten características comunes: compromiso directivo con la innovación pedagógica, capacitación sistemática del profesorado, infraestructura tecnológica confiable y culturas institucionales que valoran la experimentación educativa, por el contrario, implementaciones que carecen de estos factores tienden a generar resultados marginales o incluso efectos contraproducentes asociados a resistencias y frustraciones.

El metaanálisis de Ma et al. (2014) aporta evidencia robusta sobre magnitudes de efecto, los autores reportan tamaños de efecto promedio de $d=0.42$ (intervalo de confianza 95%: 0.31-0.53) para sistemas tutores inteligentes comparados con instrucción convencional, con efectos superiores en dominios procedimentales ($d=0.51$) respecto a conceptuales ($d=0.35$). Esta variabilidad sugiere que la inteligencia artificial resulta particularmente efectiva para desarrollar competencias algorítmicas, mientras que dominios que requieren pensamiento crítico complejo demandan complementación con estrategias pedagógicas de mayor mediación humana.

Las investigaciones también documentan efectos diferenciados según perfiles estudiantiles, en concordancia con Vieriu y Petrea (2025), los estudiantes con menores niveles de competencias previas tienden a beneficiarse más significativamente de sistemas adaptativos, posiblemente porque estas plataformas proporcionan andamiajes personalizados que compensan deficiencias formativas anteriores, este dato posee implicaciones de equidad educativa, sugiriendo que las tecnologías adaptativas podrían contribuir a reducir brechas académicas si se implementan con intencionalidad inclusiva.

Propuesta de modelo de aprendizaje adaptativo para universidades ecuatorianas

A partir del análisis realizado, se propone un modelo de aprendizaje adaptativo contextualizado que articula cinco componentes interrelacionados, diseñados considerando las particularidades institucionales, culturales y tecnológicas del sistema universitario ecuatoriano.

Componente 1: Sistema de diagnóstico integral multidominio

El primer componente trata sobre el proceso inicial de evaluación de tres aspectos del perfil estudiantil, en lo que respecta al Componente Cognitivo, hay evaluación del conocimiento disciplinario previo mediante prueba adaptativa computarizada, que cambia automáticamente el nivel de dificultad obteniendo información sobre las respuestas entregadas. En el Componente Motivacional, hay evaluación sobre intereses educativos, expectativas educativas, percepción sobre autoeficacia, realizada mediante forma validada psicométricamente. Por último, el Componente Estratégico investiga hábitos de aprendizaje, hábitos de estudio, habilidad básica digital, que condicionan uso efectivo de herramientas TIC.

Los datos obtenidos alimentan un perfil dinámico del alumno, que se actualiza permanentemente con su progresión en su trayectoria formativa; por tanto, el perfil combina datos cuantitativos (resultados, tiempos de respuesta, patrón de navegación) con datos cualitativos (reflexiones metacognitivas, preguntas al claustro, participación colaborativa en



actividades), con objeto de lograr una representación multidimensional orientada al cumplimiento de objetivos algorítmicos.

Componente 2: Motor algorítmico de personalización pedagógica

El núcleo tecnológico del modelo se basa en algoritmos de aprendizaje automático supervisado para elaborar rutas de formación individualizadas, específicamente, se plantea una propuesta híbrida que combine árboles de decisión para el clasificador inicial de los estudiantes en tipos de aprendizaje con redes neuronales profundas para la predicción continua de trayectorias. Por consiguiente; la aplicación informática se basa en el procesamiento de vectores de características estudiantiles para recetar rutas óptimas de contenidos, tiempos recomendados para la aplicación y estrategias didácticas diferenciadas.

De ese modo; el algoritmo funciona a través de ciclos de optimización iterativos. Primero, repone caminos formativos teniendo en cuenta modelos entrenados a partir de datos históricos de cohortes de cursos pasados, a medida que avanza el estudiante, viene controlando señales de indicación de rendimiento y compromiso, que optimiza de forma dinámica al descarriar del camino predicho. De esta forma, dicha optimización constante permite un grado de personalización cada vez mayor, equilibrado entre descubrimiento de caminos alternativos y aprovechamiento de metodologías que habían demostrado eficacia.

De manera específica en el Ecuador, se podría entrenar el modelo predictivo en al menos tres cohortes anteriores de cada programa de estudio de forma que se garantice la representatividad de la diversidad estudiantil de la universidad. A los algoritmos se les deberían calcular variables contextuales específicas que condicionan las carreras académicas en el Ecuador.

Componente 3: Repositorio modular de contenidos adaptativos

Este componente contempla la producción de materiales educativos granulares organizados según una taxonomía multinivel, en el nivel macro, los contenidos se estructuran por unidades temáticas alineadas con resultados de aprendizaje curriculares. En el nivel meso, cada unidad se desagrega en objetivos específicos de aprendizaje con sus correspondientes recursos didácticos: textos explicativos, videotutoriales, simulaciones interactivas, ejercicios de práctica y evaluaciones formativas. En el nivel micro, cada recurso se etiqueta con metadatos que especifican nivel de complejidad, prerrequisitos conceptuales, tiempo estimado de dedicación y modalidades de presentación.

Los contenidos se diseñan siguiendo principios de accesibilidad universal y diseño instruccional basado en evidencia, se privilegian explicaciones multimodales que integran representaciones verbales, gráficas y procedimentales para atender diferentes estilos de procesamiento de información. Asimismo, se incorporan estrategias de andamiaje cognitivo que proporcionan apoyos temporales progresivamente reducidos conforme el estudiante desarrolla autonomía.

Para contextos ecuatorianos, se propone priorizar la producción de contenidos en áreas disciplinares que presentan mayores índices de dificultad académica: matemáticas, física, química, estadística y metodología de investigación. Esta focalización estratégica permite optimizar inversiones institucionales concentrándolas donde se anticipan mayores impactos formativos.

Componente 4: Sistema de retroalimentación inmediata y multimodal

El feedback es un elemento pedagógico muy importante y funciona en múltiples niveles; en términos intelectuales, ofrece información exhaustiva acerca de los errores cometidos en conceptos y puntos mal entendidos. También indica materiales adicionales para resolver dificultades. Desde su vertiente metacognitiva, ofrece estadísticas personalizadas con respecto a comportamientos de aprendizaje y contribuye valiosamente a mejorar la autorregulación de aprendizajes entre los alumnos.



La retroalimentación está adaptada a perfiles estudiantiles. Para los estudiantes que tienen baja autoeficacia, el sistema destaca logros parciales y brinda estímulos motivacionales. Para estudiantes avanzados, la retroalimentación está orientada hacia misiones de mayor complejidad, estando la diferenciación emocional complementaria para la personalización cognitiva, conocida como parte integrante del aprendizaje, tomando en cuenta que las dimensiones emocionales condicionan la continuidad del aprendizaje o estudio. Dada la situación específica en Ecuador, donde existen barreras lingüísticas inherentes a una literatura académica dominada por el idioma inglés, se recomiendan herramientas de Traducción Automática que incorporen conceptos de uso de términos explicativos de textos especializados.

Componente 5: Módulo de evaluación continua y analítica predictiva

El quinto componente es la integración de capacidades de evaluación formativa con analítica predictiva para lograr intervenciones tempranas, de ese modo; el sistema monitorea continuamente indicadores de riesgo académico, tales como baja participación, tasas inconsistentes de compromiso y acumulación de déficits conceptuales, generando alertas cuando se detectan niveles elevados de probabilidad de fracaso o deserción. Estas alertas activan procesos de apoyo diferenciado, que involucran tanto al personal docente como a los servicios institucionales de acompañamiento académico. El sistema permite generar informes específicos sobre la naturaleza de las dificultades identificadas en los estudiantes, así como estrategias de intervención pedagógica pertinentes.

Simultáneamente, el módulo proporciona analítica agregada a nivel institucional que facilita procesos de mejora curricular, por tanto, los responsables de la gestión académica acceden a reportes sobre los contenidos que presentan mayor dificultad para los estudiantes, las secuencias instruccionales más efectivas y los perfiles estudiantiles que requieren diferenciación. De esta manera, el ciclo de retroalimentación de la innovación pedagógica transforma datos operativos en conocimiento para la gestión académica.

DISCUSIÓN

Por consiguiente, los resultados del análisis documental se articulan con enfoques teóricos actuales relacionados con la personalización del proceso educativo mediante el uso de tecnologías emergentes, y la propuesta formulada se inscribe en una perspectiva constructivista que subraya la necesidad de adecuar las experiencias formativas a las particularidades del estudiantado, al tiempo que integra recursos tecnológicos capaces de operar esta diferenciación a nivel institucional. De acuerdo con lo planteado por Aparicio-Gómez y Aparicio-Gómez (2024), la inteligencia artificial no debe ser concebida como una disrupción de los principios pedagógicos fundamentales, sino como una vía para potenciar capacidades educativas que históricamente han estado condicionadas por limitaciones estructurales, tanto en lo temporal como en lo material y cognitivo, especialmente en lo que respecta a la labor docente.

A continuación, el análisis de la evidencia empírica revisada permite sostener que los sistemas adaptativos generan mejoras consistentes, aunque de magnitud moderada, en los resultados de aprendizaje, siendo estos efectos comparables con los obtenidos mediante otras estrategias de innovación educativa ampliamente reconocidas, como lo son el aprendizaje colaborativo estructurado o la retroalimentación formativa de carácter sistemático. Aunque el impacto registrado no alcanza niveles transformadores, su valor práctico adquiere relevancia cuando se proyecta sobre cohortes estudiantiles numerosas o procesos formativos de largo plazo, circunstancia que incrementa sustancialmente su alcance institucional.

Por otra parte, las experiencias recopiladas en diversos entornos latinoamericanos, en particular aquellas sistematizadas por Almache-Sanisaca et al. (2025), ponen de manifiesto una notable variabilidad en los resultados observados según el contexto institucional, lo que refuerza la necesidad de considerar con detenimiento los factores culturales y organizacionales que condicionan la eficacia de estas herramientas. En este sentido, no puede asumirse que las plataformas adaptativas constituyan soluciones homogéneas ni replicables de forma universal, pues su efectividad depende de cómo se integren en los ecosistemas institucionales concretos,



lo cual exige modelos de implementación sensibles a las realidades locales y alejados de transferencias mecánicas de esquemas externos.

Seguidamente, la propuesta de modelo aquí expuesta intenta establecer un equilibrio entre el desarrollo tecnológico y las particularidades contextuales que definen las condiciones reales de implementación, y se enmarca dentro de lo expuesto por Fajardo-Aguilar et al. (2023), quienes destacan que las universidades ecuatorianas presentan una infraestructura limitada y capacidades institucionales dispares que influyen de forma directa en su potencial para adoptar procesos de innovación. Con base en este diagnóstico, el diseño presentado opta por priorizar funcionalidades esenciales, recomendar una aplicación progresiva por áreas del conocimiento previamente delimitadas y resaltar la necesidad de fomentar procesos de apropiación cultural, más allá de perseguir exclusivamente niveles elevados de complejidad algorítmica.

Desde una perspectiva ética, las implicaciones que surgen de esta propuesta se entrelazan con discusiones actuales en torno a la justicia aplicada a entornos educativos mediados por tecnología, y en particular con las observaciones formuladas por Dave y Patel (2023), quienes advierten que, en ausencia de una orientación explícita hacia la equidad, los sistemas apoyados en inteligencia artificial pueden terminar reforzando desigualdades estructurales ya existentes. Esta advertencia cobra una dimensión aún más relevante en el contexto ecuatoriano, caracterizado por persistentes brechas de acceso y permanencia vinculadas a factores socioeconómicos, trayectorias escolares previas y pertenencias étnicas, por lo que resulta imprescindible que las herramientas tecnológicas respondan al principio de democratización del aprendizaje, evitando contribuir a procesos de segmentación o exclusión académica.

Asimismo, el componente diagnóstico contemplado en la propuesta se apoya en los planteamientos de Orji y Vassileva (2022), quienes insisten en la necesidad de contar con caracterizaciones amplias y diversas del estudiantado, ya que las evaluaciones centradas únicamente en conocimientos disciplinares no reflejan la complejidad de los perfiles reales. La inclusión de dimensiones motivacionales y estratégicas en la recolección de datos permite enriquecer el funcionamiento de los algoritmos, aumentando así la probabilidad de generar intervenciones pedagógicas más efectivas y pertinentes a las necesidades individuales de cada estudiante.

Por otro lado, la arquitectura algorítmica planteada adopta un enfoque híbrido que busca combinar lo mejor de distintas metodologías, integrando por una parte la capacidad explicativa de los árboles de decisión, fundamentales para dotar de transparencia a los procesos que sustentan la personalización del aprendizaje, y por otra, el poder predictivo de las redes neuronales, especialmente útil para captar relaciones complejas y no lineales entre múltiples variables. Esta sinergia responde a lo señalado por Ahmed et al. (2024), quienes recomiendan el desarrollo de soluciones tecnológicas que logren articular rigor técnico con claridad operativa, favoreciendo su aceptación e integración en entornos educativos reales.

En cuanto a la selección de contenidos, se ha optado por focalizar la intervención en las áreas correspondientes a las ciencias básicas, decisión respaldada tanto por la evidencia empírica recogida por Ma et al. (2014), que sugiere una mayor eficacia de los sistemas adaptativos en dominios disciplinares específicos, como por datos locales que identifican mayores dificultades académicas en estas asignaturas dentro del sistema universitario ecuatoriano. Esta orientación estratégica permite concentrar esfuerzos en espacios con alta demanda formativa, optimizando los recursos disponibles sin comprometer las metas de innovación educativa integral.

Respecto a las funcionalidades de retroalimentación, la propuesta incorpora un enfoque coherente con los desarrollos recientes sobre autorregulación del aprendizaje, en concordancia con lo desarrollado por Gordon et al. (2024), quienes sostienen que una retroalimentación significativa no se limita a señalar errores, sino que promueve activamente el desarrollo de habilidades metacognitivas y de aprendizaje autónomo. El sistema ha sido diseñado para ofrecer orientaciones que incidan tanto en el plano cognitivo como en el metacognitivo,



favoreciendo así la consolidación de competencias duraderas que trascienden la adquisición de contenidos específicos.

Por último, el módulo de analítica predictiva se fundamenta en las investigaciones de Wang (2025), orientadas al diseño de sistemas de alerta temprana en el ámbito de la educación superior, y cuya finalidad es anticipar situaciones de riesgo académico antes de que estas se conviertan en problemáticas irreversibles. La posibilidad de actuar con antelación sobre los factores que inciden en el abandono estudiantil representa una oportunidad para desplegar estrategias de acompañamiento más eficaces, especialmente en contextos como el ecuatoriano, donde las tasas de deserción en los primeros ciclos formativos continúan representando un desafío estructural para las instituciones de educación superior.

CONCLUSION

En respuesta al objetivo planteado, se ha logrado diseñar un modelo de aprendizaje adaptativo con inteligencia artificial contextualizado para mejorar el rendimiento académico en universitarios ecuatorianos, el cual integra cinco componentes interrelacionados que articulan rigurosidad tecnológica con factibilidad operativa: sistema de diagnóstico integral multidominio, motor algorítmico de personalización pedagógica basado en aprendizaje automático supervisado, repositorio modular de contenidos adaptativos, sistema de retroalimentación inmediata y multimodal, y módulo de evaluación continua con analítica predictiva. Este modelo se distingue por su sensibilidad a las particularidades institucionales, culturales y tecnológicas del sistema universitario ecuatoriano, priorizando funcionalidades esenciales en áreas disciplinares con mayores índices de dificultad académica, contemplando limitaciones infraestructurales y promoviendo una implementación progresiva que favorezca la apropiación cultural por parte de las comunidades educativas. La propuesta fundamentada en evidencia empírica internacional y experiencias latinoamericanas, constituye una respuesta viable para potenciar trayectorias formativas estudiantiles mediante tecnologías adaptativas que, orientadas explícitamente hacia la equidad educativa, poseen potencial para incidir positivamente en la reducción de tasas de deserción y en la mejora de resultados de aprendizaje, siempre que su implementación se acompañe de compromiso institucional, capacitación docente sistemática y políticas que garanticen la democratización del acceso tecnológico.

FINANCIAMIENTO

No monetario

CONFLICTO DE INTERÉS

No existe conflicto de interés con personas o instituciones ligadas a la investigación.

AGRADECIMIENTOS

A quienes se actualizan con principios éticos para el uso de la IA en la educación.

REFERENCIAS

- Ahmed, U., Lin, J. C., & Usman, M. (2024). Student performance prediction using machine learning algorithms. *Applied Computational Intelligence and Soft Computing*, 2024, 4067721. <https://doi.org/10.1155/2024/4067721>
- Almache-Sanisaca, M. M., Ruiz-Cobos, N. J., Alverca-Jiménez, M. V., & Lalaleo-Quispe, E. M. (2025). Aprendizaje adaptativo basado en inteligencia artificial: un enfoque innovador para mejorar la preparación académica de los estudiantes universitarios [AI-based adaptive learning: An innovative approach to improving university students' academic preparedness]. *Revista Social Fronteriza*, 5(5), e-896. [https://doi.org/10.59814/resofro.2025.5\(5\)896](https://doi.org/10.59814/resofro.2025.5(5)896)
- Aparicio-Gómez, O. Y., & Aparicio-Gómez, W. O. (2024). Innovación educativa con sistemas de aprendizaje adaptativo impulsados por inteligencia artificial [Educational innovation with



- AI-powered adaptive learning systems]. *Revista Internacional de Pedagogía e Innovación Educativa*, 4(2), 343–363. <https://doi.org/10.51660/ripie42222>
- Bernik, A., Radošević, D., & Čep, A. (2025). AI-Powered Learning: Revolutionizing Education and Automated Code Evaluation. *Information*, 16(11), 1015. <https://doi.org/10.3390/info16111015>
- Bolaño-García, M., & Duarte-Acosta, N. (2024). Una revisión sistemática del uso de la inteligencia artificial en la educación [A systematic review of the use of artificial intelligence in education]. *Revista Colombiana de Cirugía*, 39(1), 51–63.
- Cortez-Granizo, D. W. (2025). Impacto de la inteligencia artificial generativa en la mejora del rendimiento académico y la retroalimentación personalizada en estudiantes universitarios [Impact of generative artificial intelligence on improved academic performance and personalized feedback in university students]. *Remulci*, 3(1), e–1171. <https://doi.org/10.59282/remulci.3.1.1171>
- Dave, M., & Patel, N. (2023). Artificial intelligence in healthcare and education. *British dental journal*, 234(10), 761–764. [https://arxiv.org/abs/2210.08186](https://doi.org/10.1038/s41415-023-5845-2Orji, F. A., & Vassileva, J. (2022). Machine learning approach for predicting students' academic performance and study strategies based on their motivation. <i>arXiv preprint</i>, arXiv:2210.08186. <a href=)
- Duran-Llano, K. L. (2023). Aprendizaje basado en problemas ABP para el pensamiento crítico en estudiantes universitarios [PBL problem-based learning for critical thinking in university students]. *Revista Multidisciplinaria Perspectivas Investigativas*, 3(4), 37–43. <https://doi.org/10.5281/zenodo.8436239>
- Fajardo-Aguilar, G. M., Ayala-Gavilanes, D. C., Arroba-Freire, E. M., & López-Quincha, M. (2023). Inteligencia artificial y la educación universitaria: una revisión sistemática [Artificial intelligence and university education: A systematic review]. *Magazine de las Ciencias: Revista de Investigación e Innovación*, 8(1), 109–131. <https://doi.org/10.33262/rmc.v8i1.2935>
- Gligorea, I., Cioca, M., Oancea, R., Gorski, A.-T., Gorski, H., & Tudorache, P. (2023). Adaptive Learning Using Artificial Intelligence in e-Learning: A Literature Review. *Education Sciences*, 13(12), 1216. <https://doi.org/10.3390/educsci13121216>
- Gordon, M., Daniel, M., Ajiboye, A., Uraiby, H., Xu, N. Y., Bartlett, R., Hanson, J., Haas, M., Spadafore, M., Grafton-Clarke, C., Gasiea, R. Y., Michie, C., Corral, J., Kwan, B., Dolmans, D., & Thammasitboon, S. (2024). A scoping review of artificial intelligence in medical education: BEME Guide No. 84. *Medical teacher*, 46(4), 446–470. <https://doi.org/10.1080/0142159X.2024.2314198>
- Gutiérrez-Castillo, J. J., Romero-Tena, R., & León-Garrido, A. (2025). Beneficios de la inteligencia artificial en el aprendizaje de los estudiantes universitarios: una revisión sistemática [Benefits of artificial intelligence in university student learning: A systematic review]. *EduTec. Revista Electrónica de Tecnología Educativa*, (91), 185–206. <https://doi.org/10.21556/edutec.2025.91.3607>
- Ma, W., Adesope, O. O., Nesbit, J. C., & Liu, Q. (2014). Intelligent tutoring systems and learning outcomes: A meta-analysis. *Journal of Educational Psychology*, 106(4), 901–918. <https://doi.org/10.1037/a0037123>
- Vieriu, A. M., & Petrea, G. (2025). The Impact of Artificial Intelligence (AI) on Students' Academic Development. *Education Sciences*, 15(3), 343. <https://doi.org/10.3390/educsci15030343>
- Wang, Y. (2025). Artificial intelligence in student management systems to enhance academic performance monitoring and intervention. *Scientific Reports*, 15, 35122. <https://doi.org/10.1038/s41598-025-19159-4>