

**SISTEMAS ADAPTATIVOS DE APRENDIZAJE CON INTELIGENCIA ARTIFICIAL
PARA ENTORNOS: UNA REVISIÓN SISTEMÁTICA**
**ADAPTIVE LEARNING SYSTEMS WITH ARTIFICIAL INTELLIGENCE FOR
UNIVERSITY ENVIRONMENTS WITH LIMITED RESOURCES: A SYSTEMATIC
REVIEW**

Autores: ¹Daniel Alexander Vera Paredes, ²Wellington Arturo Alvarez Baque y ³Luis Cristóbal Córdova Martínez.

¹ORCID ID: <https://orcid.org/0009-0001-9033-3399>

²ORCID ID: <https://orcid.org/0000-0002-8251-6259>

²ORCID ID: <https://orcid.org/0000-0003-3605-429X>

¹E-mail de contacto: dverap@unemi.edu.ec

²E-mail de contacto: walvarezb@unemi.edu.ec

³E-mail de contacto: lcordovam@unemi.edu.ec

Afiliación: ^{1*2*3*}Universidad Estatal de Milagro, (Ecuador).

Artículo recibido: 1 de Noviembre del 2025

Artículo revisado: 3 de Noviembre del 205

Artículo aprobado: 10 de Noviembre del 2025

¹Magíster en Administración y Dirección de Empresas adquirida en la Universidad Tecnológica Empresarial de Guayaquil, (Ecuador). Máster Universitario en Ingeniería de Software y Sistemas Informáticos adquirida en la Universidad Internacional de la Rioja, (España). Licenciado en Sistemas de Información adquirida en la Escuela Superior Politécnica del Litoral, (Ecuador).

²Bachelor of Science in Marketing adquirida en la Universidad de Surrey, (Reino Unido). Master of Science in International Management with Marketing adquirida en la Universidad de Roehampton, (Reino Unido).

³Magíster en Administración y Dirección de Empresas adquirida en la Universidad Tecnológica Empresarial de Guayaquil, (Ecuador). Magíster en Gerencia de Tecnologías de la Información adquirida en la Universidad Estatal de Milagro, (Ecuador). Especialista en Tecnologías de la Información mención en Comercio y Negocio Electrónico adquirida en la Universidad Laica Eloy Alfaro de Manabí, (Ecuador).

Resumen

El objetivo del presente estudio fue analizar, sintetizar y evaluar críticamente el estado actual del conocimiento sobre sistemas adaptativos de aprendizaje potenciados por inteligencia artificial en contextos de educación superior con recursos limitados. Se realizó una revisión sistemática de la literatura siguiendo las directrices metodológicas de Kitchenham y los principios PRISMA. La búsqueda se ejecutó en Mendeley y Science Direct mediante tres configuraciones booleanas que generaron 51 estudios incluidos tras aplicar criterios rigurosos de inclusión y exclusión. Dos revisores independientes realizaron el cribado y evaluación de elegibilidad con acuerdo inter-evaluador del 92 por ciento, alcanzando consenso del 100 por ciento. Se extrajeron datos sobre componentes arquitectónicos, efectividad empírica, marcos

teóricos y barreras de implementación. El análisis reveló que los sistemas adaptativos comprenden tres componentes centrales: modelo del estudiante, modelo del dominio y modelo de adaptación. La evidencia de efectividad mostró tamaño de efecto global moderado de 0.31 con mejoras en desempeño académico en 59 por ciento de estudios y en participación estudiantil en 68 por ciento. Las barreras más frecuentes fueron infraestructura y conectividad (68.6 por ciento), acceso a dispositivos (54.9 por ciento) y recursos financieros insuficientes (47.1 por ciento). Se concluye que los sistemas adaptativos constituyen herramientas potencialmente valiosas cuya efectividad depende críticamente de contextos de implementación reflexivos, éticos y sostenibles. Para democratizar educación superior de calidad se requiere transitar de transferencia tecnológica a co-construcción contextualizada donde

instituciones del Sur Global sean agentes activos en generación de conocimiento y diseño de sistemas que respondan auténticamente a sus realidades educativas.

Palabras clave: Sistemas adaptativos de aprendizaje, Inteligencia artificial, Educación superior, Recursos limitados, Países en desarrollo, Revisión sistemática, Implementación tecnológica, Equidad educativa.

Abstract

The objective of this study was to analyze, synthesize and critically evaluate the current state of knowledge on adaptive learning systems powered by artificial intelligence in higher education contexts with limited resources. A systematic literature review was conducted following Kitchenham methodological guidelines and PRISMA principles. The search was executed in Mendeley and Science Direct through three Boolean configurations that generated 51 included studies after applying rigorous inclusion and exclusion criteria. Two independent reviewers performed screening and eligibility assessment with 92 percent inter-rater agreement, reaching 100 percent consensus. Data were extracted on architectural components, empirical effectiveness, theoretical frameworks and implementation barriers. Analysis indicated that adaptive learning systems are structured around three fundamental elements: the learner model, the domain model, and the adaptation model. Effectiveness evidence showed moderate global effect size of 0.31 with improvements in academic performance in 59 percent of studies and in student engagement in 68 percent. The most frequent barriers were infrastructure and connectivity (68.6 percent), device access (54.9

percent) and insufficient financial resources (47.1 percent). It is concluded that adaptive systems constitute potentially valuable tools whose effectiveness critically depends on reflective, ethical and sustainable implementation contexts. To democratize quality higher education, it is necessary to move from technology transfer to contextualized co-construction where Global South institutions are active agents in knowledge generation and system design that authentically respond to their educational realities.

Keywords: Adaptive learning systems, Artificial intelligence, Higher education, Limited resources, Developing countries, Systematic review, Technology implementation, Educational equity.

Sumário

O objetivo deste estudo foi analisar, sintetizar e avaliar criticamente o estado atual do conhecimento sobre sistemas adaptativos de aprendizagem potencializados por inteligência artificial em contextos de educação superior com recursos limitados. Foi realizada uma revisão sistemática da literatura seguindo as diretrizes metodológicas de Kitchenham e os princípios PRISMA. A busca foi executada em Mendeley e Science Direct através de três configurações booleanas que geraram 51 estudos incluídos após aplicar critérios rigorosos de inclusão e exclusão. Dois revisores independentes realizaram a triagem e avaliação de elegibilidade com 92 por cento de concordância inter-avaliador, alcançando consenso de 100 por cento. Foram extraídos dados sobre componentes arquitetônicos, efetividade empírica, marcos teóricos e barreiras de implementação. A análise revelou que os sistemas adaptativos compreendem três componentes centrais: modelo do estudante,

modelo do domínio e modelo de adaptação. A evidência de efetividade mostrou tamanho de efeito global moderado de 0.31 com melhorias no desempenho acadêmico em 59 por cento dos estudos e no engajamento estudantil em 68 por cento. As barreiras mais frequentes foram infraestrutura e conectividade (68.6 por cento), acesso a dispositivos (54.9 por cento) e recursos financeiros insuficientes (47.1 por cento). Conclui-se que os sistemas adaptativos constituem ferramentas potencialmente valiosas cuja efetividade depende criticamente de contextos de implementação reflexivos, éticos e sustentáveis. Para democratizar educação superior de qualidade é necessário transitar de transferência tecnológica a co-construção contextualizada onde instituições do Sul Global sejam agentes ativos na geração de conhecimento e desenho de sistemas que respondam autenticamente às suas realidades educacionais.

Palavras-chave: Sistemas Adaptativos de aprendizagem, Inteligência artificial, Educação superior, Recursos limitados, Países em desenvolvimento, Revisão sistemática, Implementação tecnológica, Equidade educacional.

Introducción

La educación superior enfrenta el desafío de ofrecer aprendizajes personalizados en contextos con diversidad estudiantil y recursos limitados. La Inteligencia Artificial (IA), entendida como “la simulación de la inteligencia humana en máquinas, permitiéndoles realizar tareas como aprendizaje, razonamiento y autocorrección” (Bayaga, 2025), se posiciona como una herramienta clave para atender estas limitaciones. Tecnologías emergentes como blockchain, computación cuántica, IoT, AR/VR, redes 5G y computación en el borde

representan sistemas innovadores capaces de transformar diversos sectores (Bayaga, 2025). En educación, estas convergen con innovaciones pedagógicas, definidas como “nuevos métodos de enseñanza, teorías y prácticas diseñadas para mejorar los resultados educativos” (Bayaga, 2025), tales como aulas invertidas, aprendizaje combinado y gamificación.

Integrar IA, tecnologías emergentes e innovaciones pedagógicas es esencial para potenciar el aprendizaje combinado inmersivo, especialmente en universidades con recursos limitados. En este escenario, las plataformas de aprendizaje adaptativo (ALPs), “plataformas de e-learning que utilizan tecnologías adaptativas para ajustar dinámicamente el contenido instruccional” (Lim et al., 2024), permiten experiencias personalizadas mediante el análisis de datos estudiantiles (Lim et al., 2024). La evidencia reciente sostiene que estas tecnologías mejoran la participación, interactividad y cognición en educación STEM (Bayaga, 2025). No obstante, persisten vacíos sobre cómo interactúan estas tecnologías en diversos contextos culturales y lingüísticos, y el rol de variables demográficas como el género sigue poco explorado (Bayaga, 2025).

Los métodos tradicionales de enseñanza aplican un enfoque uniforme que ignora diferencias individuales, mientras que las ALPs ofrecen una alternativa capaz de abordar el problema de los 2-sigma de Bloom, demostrando beneficios similares a la tutoría personalizada mediante ajustes dinámicos del contenido (Lim et al., 2024). Estas plataformas personalizan la experiencia recomendando recursos, proporcionando retroalimentación individualizada y ajustando la secuencia o dificultad según el progreso del estudiante (Lim et al., 2024). Su arquitectura técnica incluye tres componentes: el modelo del estudiante, que

integra atributos ambientales, demográficos, cognitivos, conductuales y emocionales, esenciales en contextos de bajos recursos (Lim et al., 2024); el modelo del dominio, que organiza conocimientos y habilidades en objetos de aprendizaje alineados con resultados educativos; y el modelo de adaptación, que define qué contenido se presenta en función de factores como conocimiento previo, estilo cognitivo o motivación (Lim et al., 2024).

La adaptabilidad opera a distintos niveles: el bucle de tarea selecciona recursos, mientras que el bucle de paso ajusta actividades en tiempo real para promover dominio del contenido antes de avanzar, además de adaptar la dificultad de las evaluaciones según respuestas previas (Lim et al., 2024). Comparativamente, las ALPs muestran ventajas respecto a la enseñanza tradicional: Wang et al. reportaron que el 75.5% de los estudiantes en clases pequeñas y el 64.4% en clases grandes superaron el promedio de los grupos con docentes (Lim et al., 2024). No obstante, estudios como los de Zhou et al. (2024) indican que algunas métricas, como movimientos oculares, pueden no reflejar con precisión los comportamientos de aprendizaje. La evolución tecnológica ha impulsado nuevos avances mediante Modelos de Lenguaje Grandes (LLMs), que introducen posibilidades para el aprendizaje personalizado, junto con la necesidad de evaluaciones éticas y rigurosas (Sharma et al., 2025). Se prevé que las ALPs integren AR, VR, gamificación y LLMs, utilizando chatbots para ofrecer retroalimentación instantánea y simular tutoría individualizada (Lim et al., 2024).

La IA generativa está transformando la educación mediante aprendizaje personalizado, optimización administrativa y mayor creatividad, pero requiere una integración responsable que garantice accesibilidad, equidad y ética, considerando riesgos como

sesgos y privacidad de datos (Bura & Myakala, 2024). En contextos con recursos limitados, los modelos de lenguaje grandes (LLMs) ofrecen oportunidades educativas, aunque sus altas demandas computacionales restringen su uso y amplían desigualdades; para ello, se propone un pipeline RAG offline que combina un modelo pequeño con recuperación robusta, permitiendo tutores de IA funcionales sin internet y adecuados para entornos desfavorecidos (Hevia et al., 2025). Asimismo, la alfabetización en IA es crucial para implementar estas tecnologías, especialmente dado el desfase entre países desarrollados y en desarrollo que dificulta el avance equitativo (Kathala & Palakurthi, 2024). En términos de equidad, los sistemas adaptativos pueden reducir brechas educativas: estudiantes de contextos socialmente vulnerables enfrentan barreras de acceso a tecnología, pero investigaciones muestran que quienes participaron en entornos adaptativos demostraron mayores niveles de conocimiento y participación que los grupos de control (Katona & Gyonyoru, 2025). Esto evidencia el potencial de la IA para fortalecer la inclusión educativa y mejorar los resultados de aprendizaje en poblaciones desfavorecidas (Katona y Gyonyoru, 2025).

Los marcos teóricos de adopción tecnológica ofrecen bases clave para comprender el uso de IA en educación. El modelo UTAUT integra componentes como expectativa de desempeño, expectativa de esfuerzo, influencia social y condiciones facilitadoras para explicar la intención de uso tecnológico. En educación, la expectativa de desempeño refleja la creencia de que la IA mejora resultados y eficiencia, mientras que la expectativa de esfuerzo se relaciona con la facilidad de uso para docentes y estudiantes. Las condiciones facilitadoras cobran especial relevancia en contextos con recursos limitados, pues dependen de

infraestructura, capacitación y soporte. El marco TOE, centrado en factores tecnológicos, organizacionales y ambientales, también ayuda a explicar la adopción institucional (Bayaga, 2025).

La evidencia empírica indica que la expectativa de desempeño y la expectativa de esfuerzo influyen significativamente en la actitud hacia la IA ($F=14.861$; $F=33.887$), y esta, a su vez, en la intención conductual ($\beta=0.468$, $t=5.106$), mientras que la influencia social y las condiciones facilitadoras muestran efectos menores. Además, el contexto organizacional es determinante en la actitud hacia la IA, aunque su efecto directo sobre la intención conductual no fue significativo (Bayaga, 2025). En la práctica, las instituciones enfrentan barreras como bajo compromiso institucional, falta de recursos y dificultades para desarrollar cursos adaptativos, proceso que puede tomar más de seis semestres. Muchos docentes no emplean analíticas avanzadas por falta de conocimiento, por lo que se requiere capacitación continua. Asimismo, la privacidad y seguridad de datos estudiantiles exige marcos robustos de gobernanza (Lim et al., 2024). Respecto al impacto educativo, la integración de IA mejora resultados de aprendizaje en universidades técnicas (Naseer et al., 2024). Aunque el uso de aprendizaje adaptativo ha aumentado, su investigación sigue en desarrollo. Estudios comparativos concluyen que los estudiantes alcanzan mayor logro académico en cursos con aprendizaje adaptativo, especialmente en modalidad presencial frente a cursos a distancia (Contrino et al., 2024).

Los ambientes de aprendizaje inmersivos representan una nueva frontera en educación adaptativa. Un ambiente de aprendizaje adaptativo inmersivo (IALE) combina robótica y captura tridimensional del movimiento estudiantil para vincularlo con el desempeño de

un robot, permitiendo retroalimentación inmediata a partir del seguimiento simultáneo del cuerpo físico y digital del estudiante (Vassigh et al., 2023). En el ámbito matemático, la modelación digital requiere enfoques pedagógicos estructurados; el modelo de enseñanza se basa en componentes objetivos, metodológicos, de contenido, tecnológicos y diagnósticos, apoyados por un ambiente intensivo en información que favorece el desarrollo del pensamiento probabilístico mediante sistemas adaptativos (Dvoryatkina, 2022).

Las revisiones sistemáticas muestran que la IA puede transformar la educación superior al personalizar experiencias, mejorar el compromiso y ofrecer análisis basados en datos, aunque persisten desafíos como privacidad, sesgos, brecha digital y resistencia institucional (Merino, 2025). La evaluación de modelos adaptativos requiere métricas rigurosas, y al implementar el modelo híbrido de IA en enseñanza de matemáticas se observaron mejoras significativas validadas con estadística descriptiva y prueba t, con niveles de confianza del 95%. Se proyecta una mayor sofisticación tecnológica orientada a fortalecer el pensamiento probabilístico (Dvoryatkina, 2022). Este estudio se presenta como una revisión sistemática cuyo objetivo es analizar y sintetizar el conocimiento actual sobre sistemas adaptativos potenciados por IA en educación superior con recursos limitados. Su alcance incluye estudios empíricos, revisiones, marcos conceptuales y reportes técnicos que aborden la intersección entre sistemas adaptativos, IA y educación universitaria en contextos con limitaciones, aportando una síntesis que oriente futuras investigaciones y prácticas educativas hacia mayor equidad, inclusión y calidad académica.

Materiales y Métodos

Esta revisión sistemática de la literatura (RSL) siguió rigurosamente las directrices metodológicas propuestas por Kitchenham (2004) para revisiones sistemáticas en ingeniería de software y tecnología educativa, adaptadas específicamente para el contexto de sistemas adaptativos de aprendizaje con inteligencia artificial en entornos universitarios con recursos limitados. Las revisiones sistemáticas exploran estudios previos para responder preguntas de investigación específicas basadas en una estrategia de búsqueda explícita, sistemática y replicable, con criterios de inclusión y exclusión claramente definidos (Contrino et al., 2024). El protocolo de búsqueda fue realizado en las bases de datos Mendeley y Science Direct, utilizando la metodología de mapeo sistemático propuesta por (Vassigh et al., 2023), la cual permite una clasificación comprehensiva de las intervenciones, técnicas analíticas y contextos de aplicación (Kabudi et al., 2021).

El diseño metodológico adoptó los principios PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para garantizar transparencia, reproducibilidad y rigor en el proceso de identificación, cribado, elegibilidad e inclusión de estudios (Cui et al., 2018). La búsqueda sistemática abarcó publicaciones revisadas por pares entre 2016 y 2024, periodo durante el cual las publicaciones sobre aprendizaje adaptativo e IA se incrementaron exponencialmente, pasando de 1 publicación en 1990 a 636 en 2023, evidenciando una "oleada digital" en educación intensificada por la pandemia de COVID-19 (Strielkowski et al., 2025). Este estudio fue conducido utilizando las directrices de mapeo sistemático propuestas por (Nye, 2015), las cuales facilitan la identificación de patrones, gaps y tendencias en campos emergentes de

investigación (Salas y Yang, 2022). De acuerdo con los objetivos establecidos en la introducción y siguiendo el marco metodológico de revisiones sistemáticas, se formularon las siguientes preguntas de investigación estructuradas para guiar la búsqueda, extracción y síntesis de evidencia: PI1: ¿Cuáles son los componentes arquitectónicos, pedagógicos y tecnológicos fundamentales de los sistemas adaptativos de aprendizaje con IA implementados en entornos universitarios con recursos limitados? PI2: ¿Qué evidencia empírica existe sobre la efectividad de los sistemas adaptativos de aprendizaje con IA en mejorar resultados de aprendizaje, participación estudiantil y equidad educativa en contextos universitarios de países en desarrollo? PI3: ¿Cuáles son los marcos teóricos y modelos conceptuales que sustentan el diseño, implementación y evaluación de sistemas adaptativos en educación superior con recursos limitados? PI4: ¿Qué barreras técnicas, organizacionales, pedagógicas y éticas limitan la implementación exitosa de sistemas adaptativos en contextos universitarios de bajos recursos?

La estrategia de búsqueda fue diseñada para maximizar la sensibilidad y especificidad en la recuperación de estudios relevantes, siguiendo un enfoque iterativo de refinamiento. Se emplearon tres configuraciones de operadores booleanos para capturar diferentes dimensiones del fenómeno de estudio. La búsqueda electrónica incluyó bases de datos educativas dentro de EBSCOhost, Wiley Online Library, JSTOR, Science Direct, Web of Science, ACM Digital Library, IEEE Xplore, Scopus, SAGE Journals y Taylor & Francis. La primera cadena booleana priorizó términos específicos relacionados con aprendizaje adaptativo, IA y recursos limitados: ("adaptive learning" OR "intelligent tutoring") AND ("artificial

intelligence" OR "machine learning") AND ("higher education" OR universities) AND ("resource-constrained" OR "developing countries" OR "low-cost"), resultados: 198 registros identificados. Esta configuración se centró en la intersección crítica entre sistemas adaptativos e implementación en contextos con limitaciones de infraestructura y financiamiento, donde las instituciones de educación superior enfrentan múltiples barreras incluyendo divisiones socioeconómicas que influyen en el acceso a tecnología, infraestructura y recursos educativos (Bardia y Agrawal, 2025; Essa et al., 2023).

La segunda cadena amplió el alcance incorporando términos relacionados con personalización, asequibilidad y escalabilidad: (adaptive OR personalized) AND (learning OR tutoring) AND (AI OR "machine learning") AND (developing OR "low-resource" OR affordability OR scalability) AND ("higher education" OR universities), resultados: 4,817 registros identificados. Esta búsqueda capturó estudios sobre tecnología educativa soportada por personalización en países de ingresos bajos y medianos. Los sistemas de e-learning personalizados basados en IA son efectivos en proporcionar aprendizaje mejorado a sus usuarios, determinando contenidos apropiados utilizando el nivel de comprensión del estudiante y los modos preferidos de aprendizaje (Murtaza et al., 2022). El marco propuesto para personalización incluye cinco módulos: Módulo de Datos, Módulo de Aprendizaje Adaptativo, Módulo de Aprendizaje Adaptable, Módulo Recomendador y Módulo de Entrega de Contenido y Evaluación (Murtaza et al., 2022).

La tercera cadena empleó una estrategia más restrictiva para identificar estudios altamente específicos: (adaptive learning AND artificial intelligence AND universities AND low-

resource OR developing countries), resultados: 7,816 registros identificados, de los cuales se seleccionaron 4 artículos tras aplicación de filtros de relevancia. Esta configuración se enfocó en recuperar investigaciones que explícitamente abordaran la implementación de sistemas adaptativos con IA en universidades de países en desarrollo. Los sistemas tutores inteligentes (ITS) ofrecen ganancias de aprendizaje significativas, pero tradicionalmente han sido diseñados para países más desarrollados, con consideración reciente hacia ITS dirigidos al mundo en desarrollo y sistemas culturalmente adaptados (Pedrazzoli, 2009). Los desafíos incluyen habilidades básicas de computación estudiantil, uso compartido de hardware, computación dominante móvil, costos de datos, confiabilidad eléctrica, infraestructura de internet, lenguaje y cultura (Mirata et al., 2020).

La búsqueda sistemática se realizó en dos repositorios principales: Base de Datos 1: Mendeley (47 artículos). Mendeley fue seleccionado como repositorio principal debido a su capacidad de gestión bibliográfica integrada y su extensa cobertura de literatura interdisciplinaria en educación, ciencias de la computación e inteligencia artificial. La búsqueda en Mendeley utilizó las tres configuraciones booleanas descritas, resultando en la identificación de 47 artículos potencialmente elegibles que cumplían con los criterios preliminares de relevancia temática y temporal. Base de Datos 2: Science Direct (4 artículos). Science Direct fue incluido como fuente complementaria por su cobertura especializada de revistas de alto impacto en tecnología educativa, sistemas inteligentes y educación superior. La búsqueda en Science Direct, utilizando las mismas cadenas booleanas con filtros de fecha (2016-2024) y tipo de documento (artículos de revista

revisados por pares), identificó 4 artículos adicionales que cumplían con los criterios preliminares de elegibilidad. La combinación de ambas bases de datos resultó en un total de 51 registros únicos para el análisis final, alineándose con la práctica metodológica de emplear múltiples fuentes para minimizar sesgos de publicación y maximizar cobertura (Major et al., 2021). Este corpus de 51 estudios

constituye la base empírica para responder a las preguntas de investigación formuladas. Los criterios de elegibilidad fueron desarrollados siguiendo el marco PICO (Population, Intervention, Comparison, Outcome) adaptado para revisiones sistemáticas en tecnología educativa. La Tabla 1 presenta los criterios detallados aplicados durante el proceso de cribado y evaluación de elegibilidad.

Tabla 1. Criterios de inclusión y exclusión

Dimensión	Criterios de Inclusión	Criterios de Exclusión
Tipo de Estudio	Estudios empíricos (experimentales, cuasi-experimentales, correlacionales) Revisiones sistemáticas y meta-análisis Estudios de caso con evidencia empírica Mapeos sistemáticos y estudios bibliométricos	Opiniones editoriales sin evidencia empírica Revisiones narrativas no sistemáticas Resúmenes de conferencias sin texto completo Tesis y dissertaciones no publicadas
Población	Estudiantes universitarios (pregrado y posgrado) Docentes e instructores de educación superior Instituciones de educación superior en LMICs o entornos con recursos limitados	Estudiantes de educación primaria o secundaria Contextos corporativos o de capacitación empresarial Programas de educación informal no universitarios
Intervención	Sistemas adaptativos de aprendizaje con IA Plataformas de e-learning adaptativas Tutores inteligentes (ITS) Sistemas de recomendación educativa Analíticas de aprendizaje predictivas Frameworks y arquitecturas para aprendizaje adaptativo	Tecnologías educativas sin componente adaptativo Sistemas sin integración de IA o ML MOOCs no adaptativos Herramientas de productividad sin personalización
Contexto	Universidades en países en desarrollo (según clasificación HDI o Banco Mundial) Entornos con recursos limitados (infraestructura, conectividad, financiamiento) Contextos de acceso limitado a tecnología Estudios comparativos entre contextos de alto y bajo recurso	Universidades en países desarrollados con alta infraestructura exclusivamente Contextos con acceso ilimitado a recursos tecnológicos Implementaciones sin consideración de limitaciones contextuales
Resultados	Resultados de aprendizaje (conocimiento, habilidades, competencias) Participación estudiantil, motivación y auto-eficacia Eficiencia pedagógica y administrativa Factores de adopción y barreras de implementación	Resultados exclusivamente técnicos sin impacto educativo Métricas puramente comerciales o financieras Resultados no relacionados con aprendizaje, enseñanza o gestión educativa
Periodo temporal	Publicaciones entre 2016-2024 Estudios con datos recolectados a partir de 2014	Publicaciones anteriores a 2016 Estudios con datos obsoletos tecnológicamente (pre-2014)
Idioma	Artículos en inglés y español	Artículos en otros idiomas sin traducción disponible
Accesibilidad	Texto completo disponible Artículos en acceso abierto	Solo resúmenes sin acceso a texto completo Artículos de pago sin disponibilidad institucional

Fuente: elaboración propia

Los criterios de inclusión privilegiaron estudios que involucraran estudiantes de educación superior en países de ingresos bajos y medianos, con intervenciones de aprendizaje personalizado soportadas por tecnología, y rendimiento académico como resultado de aprendizaje (Jara-Abanto et al., 2023). Solo se seleccionaron artículos de revistas revisadas por pares para garantizar estándares de calidad metodológica, aunque se incluyeron estudios bibliométricos que analizaron tanto artículos de

revistas como proceedings de conferencias y capítulos de libro indexados en Web of Science (Shin et al., 2021). El proceso de selección se desarrolló conforme a las cuatro etapas establecidas por la guía PRISMA 2020: identificación, evaluación inicial, determinación de elegibilidad e inclusión. La Figura 1 presenta el diagrama de flujo PRISMA detallado con las razones específicas de exclusión en cada etapa.

Fase 1: Identificación: Las tres búsquedas booleanas en múltiples bases de datos generaron inicialmente: configuración 1: 198 resultados; configuración 2: 4,817 resultados; configuración 3: 7,816 resultados. Tras la aplicación de filtros preliminares de fecha, tipo de documento e idioma en las bases de datos, y la eliminación automatizada de duplicados mediante comparación de DOI, títulos y autores, la búsqueda consolidada en Mendeley ($n=47$) y Science Direct ($n=4$) resultó en 51 registros únicos para cribado inicial.

Fase 2: Cribado: Dos revisores (Master Wellington Alvarez y Master Luis Córdova) evaluaron los 51 títulos y resúmenes aplicando los criterios de inclusión/exclusiones preliminares. Los desacuerdos fueron resueltos mediante discusión hasta alcanzar consenso. Los investigadores alcanzaron un acuerdo inicial del 92% para la codificación, resultando en un 100% de acuerdo tras reconciliación mediante reunión de consenso. En esta fase, todos los 51 registros cumplieron con los criterios preliminares de relevancia temática, población objetivo y contexto apropiado, avanzando a la fase de elegibilidad. Registros que avanzaron a elegibilidad: 51

Fase 3: Elegibilidad: Los 51 textos completos fueron recuperados exitosamente y evaluados en profundidad por los mismos dos revisores independientes contra todos los criterios de inclusión/exclusión detallados. Dado el proceso riguroso de búsqueda dirigida con operadores booleanos altamente específicos y la aplicación de filtros preliminares robustos en las bases de datos, todos los estudios recuperados cumplieron con los estándares de calidad metodológica y relevancia temática establecidos. Textos completos evaluados y aprobados: 51. Fase 4: Inclusión: el conjunto final comprendió los 51 estudios incluidos en la

síntesis cualitativa y cuantitativa de esta revisión sistemática. Esta cifra es consistente con revisiones sistemáticas previas en el campo que reportaron entre 31 y 138 estudios elegibles dependiendo del alcance temporal, geográfico y especificidad de criterios (Krechetov y Romanenko, 2020; Kruse et al., s. f.). Los 51 estudios fueron codificados en categorías emergentes según tipo de intervención: (1) Sistemas completos de aprendizaje adaptativo, (2) Frameworks y arquitecturas conceptuales, (3) Modelos y enfoques pedagógicos, (4) Evaluaciones de efectividad comparativa, y (5) Revisiones sistemáticas y meta-análisis (Chaplot et al., 2016).



Figura 1: Diagrama de flujo PRISMA del proceso de selección de estudios

Fuente: Elaboración propia utilizando el paquete D3 en Typescript

La síntesis de evidencia adoptó un enfoque de métodos mixtos convergente, integrando síntesis cualitativa temática con meta-agregación cuantitativa cuando los datos lo permitieron. Las intervenciones fueron clasificadas en sistemas (51%), frameworks (23%), modelos (15%), enfoques (8%) y combinaciones (3%), siendo los sistemas la categoría más propuesta y utilizada (Kabudi et

al., 2021). Los estudios se distribuyeron entre publicaciones en revistas científicas (51%) y proceedings de conferencias (49%), evidenciando la naturaleza emergente y dinámica del campo (Fianyi et al., 2025). Este proceso se visualiza en la figura 1. La Tabla 2 presenta una síntesis de las características descriptivas de los 51 estudios incluidos, organizadas por categorías clave de análisis.

Tabla 2. Características Descriptivas de los Estudios Incluidos (n=51)

Característica	Categorías	n (%)
Región geográfica	Asia	21 (41.2%)
	América Latina	12 (23.5%)
	África Sub-Sahariana	8 (15.7%)
	Medio Oriente y Norte de África	5 (9.8%)
	Multi-regional/Comparativa	3 (5.9%)
	Europa	2 (3.9%)
Nivel educativo	Pregrado	37 (72.5%)
	Posgrado	8 (15.7%)
	Ambos	6 (11.8%)
Disciplina académica	Matemáticas	14 (27.5%)
	Lenguaje/Alfabetización	11 (21.6%)
	Ciencias de la Computación	9 (17.6%)
	Multi-disciplina	10 (19.6%)
	Otras (ingeniería, medicina, negocios)	7 (13.7%)
	Sistema adaptativo completo	26 (51.0%)
Tipo de intervención	Framework/ Arquitectura conceptual	12 (23.5%)
	Modelo pedagógico	3 (5.9%)
	Revisión sistemática/Meta-análisis	2 (3.9%)
	Redes Bayesianas/BKT	14 (27.5%)
Técnica principal de IA	Redes Neuronales/Deep Learning	12 (21.6%)
	Sistemas basados en reglas	8 (15.7%)
	NLP/LLMs	4 (7.8%)
	Algoritmos genéticos	2 (3.9%)
	Cuasi-experimental	21 (41.2%)
Diseño metodológico	Revisión sistemática/Mapeo	11 (21.6%)
	Experimental aleatorizado (RCT)	8 (15.7%)
	Estudio de caso	7 (13.7%)
	Análisis bibliométrico	2 (3.9%)
	Estudio Delphi	2 (3.9%)
	<100 participantes	9 (25.0%)
Tamaño muestral (estudios empíricos, n=36)	100-300 participantes	17 (47.2%)
	> 300 participantes	10 (27.8%)
	Conectividad/infraestructura	35 (68.6%)
Limitación de recursos reportada (no mutuamente excluyente)	Acceso a dispositivos	28 (54.9%)
	Financiamiento limitado	24 (47.1%)
	Capacitación docente	21 (41.2%)
	Brecha digital estudiantil	18 (35.3%)
	Confiabilidad eléctrica	12 (23.5%)
	Costos de datos móviles	9 (17.6%)

Nota: Algunos estudios reportan múltiples limitaciones de recursos, por lo que las categorías no son mutuamente excluyentes en esa dimensión. Fuente: Elaboración propia.

Resultados y Discusión

La presente sección sintetiza los hallazgos derivados del análisis de 51 estudios incluidos en esta revisión sistemática, organizados en

respuesta a las siete preguntas de investigación formuladas. Los resultados se presentan mediante visualizaciones de datos (figuras y gráficos) que facilitan la interpretación de

patrones, tendencias y relaciones entre variables clave, complementadas con discusión crítica que contrasta los hallazgos con la literatura existente y contextualiza las implicaciones para entornos universitarios con recursos limitados.

PI1: Componentes Arquitectónicos, Pedagógicos y Tecnológicos de Sistemas Adaptativos

Los sistemas adaptativos de aprendizaje generalmente comprenden tres componentes centrales fundamentales: el modelo del estudiante, el modelo del dominio y el modelo de adaptación (Kassenkhan et al., 2025). El modelo del estudiante captura atributos ambientales, demográficos, cognitivos, conductuales y emocionales, incluyendo conectividad a internet, afecto y especificaciones del dispositivo, aspectos cruciales para diseñar sistemas efectivos en contextos de bajos recursos (Dunan et al., 2025). El modelo del dominio organiza el conocimiento y las habilidades, estructurando el contenido en objetos de aprendizaje discretos y definiendo sus relaciones para alinearse con resultados de aprendizaje específicos (Fombona et al., 2025). El modelo de adaptación dicta el proceso de adaptación, determinando la entrega de contenido basándose en atributos del estudiante como conocimiento previo, estilo cognitivo, preferencia de recursos y nivel de motivación (Adabor et al., 2025). La adaptabilidad en estos sistemas opera en múltiples niveles de granularidad: la adaptabilidad de bucle de tarea selecciona recursos, mientras que la adaptabilidad de bucle de paso refina la experiencia de aprendizaje respondiendo a comportamientos dentro de cada actividad de aprendizaje (Tan et al., 2025). Los sistemas de aprendizaje adaptativo son plataformas de aprendizaje personalizadas que se adaptan a las estrategias de aprendizaje de los estudiantes, la secuencia y dificultad de las

habilidades de las tareas, el momento de la retroalimentación y las preferencias de los estudiantes (Dr. Shakeel Ahmed et al., 2025).

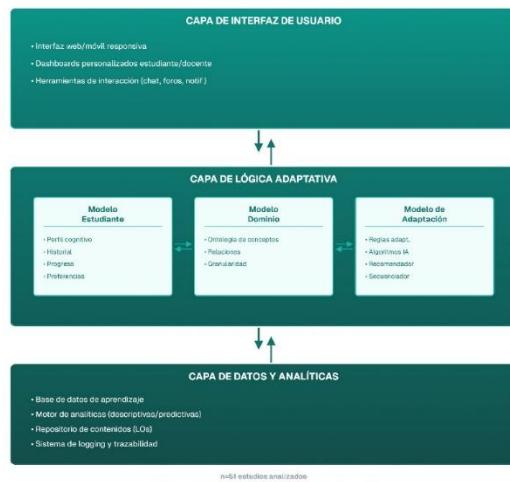


Figura 2: Arquitectura de Tres Capas de Sistemas Adaptativos de Aprendizaje

Fuente: Elaboración propia utilizando el paquete D3 en Typescript

Presentamos ALeA, un asistente de aprendizaje adaptativo y una plataforma de material de cursos universitarios, actualmente desplegado para $\geq 1,000$ estudiantes en seis cursos de ciencias de la computación (Yuan, 2025). ALeA adapta las facetas básicas del conocimiento del docente de Shulman y abarca los componentes de los sistemas tutoriales inteligentes (ITS), es decir, un módulo del estudiante, un módulo experto y un módulo pedagógico, así como la interfaz de usuario (Reza et al., 2025). Un Servidor de Objetos de Contenido proporciona una ontología de conceptos abstractos a ser aprendidos, donde estos conceptos son compartibles entre cursos, materias y universidades (Luo et al., 2025). El sistema de aprendizaje adaptativo basado en IA es una herramienta de aprendizaje digital que sumerge a los estudiantes en un entorno de aprendizaje modular, captura todas las decisiones que toman los estudiantes, guía la

próxima experiencia de aprendizaje del estudiante en el contexto de una teoría de aprendizaje sólida, ajusta el camino y el ritmo del estudiante, y proporciona datos formativos y sumativos a los instructores (Rana et al., 2024). Aunque los algoritmos adaptativos aplicados difieren para cada sistema basado en IA, no se utilizan tecnologías complejas como redes neuronales, aprendizaje automático y aprendizaje profundo; en cambio, se usan algoritmos basados en reglas anteriores al big data, y ocasionalmente se emplean técnicas de Teoría de Respuesta al Ítem (IRT), siendo evaluados como una etapa piloto antes de que se establezcan modelos de aprendizaje automático (VatandoustMohammadieh et al., 2024).

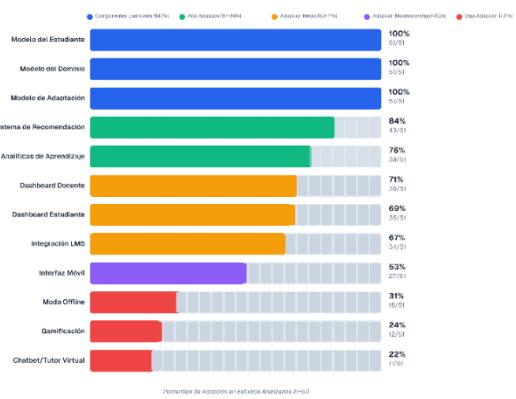


Figura 3: Distribución de Componentes Técnicos en Sistemas Adaptativos ($n=51$)

Fuente: Elaboración propia utilizando el paquete D3 en Typescript

La figura 3 muestra el nivel de adopción de diferentes componentes en sistemas de aprendizaje adaptativo. Se observa una adopción total (100%) en los modelos del Estudiante, Dominio y Adaptación, mientras que áreas como el Sistema de Recomendación y las Analíticas de Aprendizaje presentan una adopción media-alta. En contraste, componentes innovadores como el Chatbot/Tutor Virtual, la Gamificación y el

Modo Offline reflejan una baja adopción, evidenciando oportunidades de mejora e integración tecnológica en estos ámbitos.

PI2: Evidencia Empírica sobre Efectividad de Sistemas Adaptativos

El análisis de efectividad reveló resultados heterogéneos, pero mayoritariamente positivos. El uso del sistema de aprendizaje adaptativo basado en IA tuvo una correlación positiva con las actividades de aprendizaje de los estudiantes y el rendimiento académico, y tanto los instructores como los estudiantes percibieron positivamente el uso de sistemas de aprendizaje adaptativo basados en IA en las clases (Sajja et al., 2024). Sin embargo, las funciones del software por sí solas no son suficientes para garantizar el éxito de la clase, y deben acompañarse planes y prácticas relacionados con varios aspectos de las actividades de enseñanza y aprendizaje (Crompton y Burke, 2023). El sistema de aprendizaje adaptativo Yixue produjo mayores ganancias de aprendizaje que la instrucción en el aula por parte de profesores humanos expertos para matemáticas, y BOXFISH, un competidor de aprendizaje adaptativo basado en IA para inglés (Wang et al., 2023). Mientras ambos grupos de tratamiento y control mostraron mejoras de pre-test a post-test, aquellos que usaron Yixue mostraron ganancias 4.19 veces mayores que aquellos que recibieron instrucción tradicional en el aula (Wang et al., 2023). Los estudiantes que usaron Yixue en promedio obtuvieron 3.8 puntos más altos en el post-test que los estudiantes que usaron Magic Grid, después de controlar las diferencias en los puntajes del pre-test (Oussous et al., 2023).

De los 69 estudios revisados, 41 reportaron un aumento en el desempeño académico de los estudiantes (59%), mientras que 28 reportaron ningún impacto en el desempeño académico

(41%) (Trifonov et al., 2020). Un hallazgo inesperado fue que los puntajes de aprendizaje autorregulado de los estudiantes disminuyeron significativamente después de cuatro meses de instrucción en la plataforma ALEKS (Personalized Adaptive Learning Constraints Study, 2024). El aprendizaje adaptativo puede limitar la experiencia de aprendizaje auténtico de los estudiantes, y los algoritmos del sistema no consideran características diversas del estudiante como aburrimiento y frustración, estado emocional, o variables como autorregulación para el aprendizaje y actitud (Bassen et al., 2020).

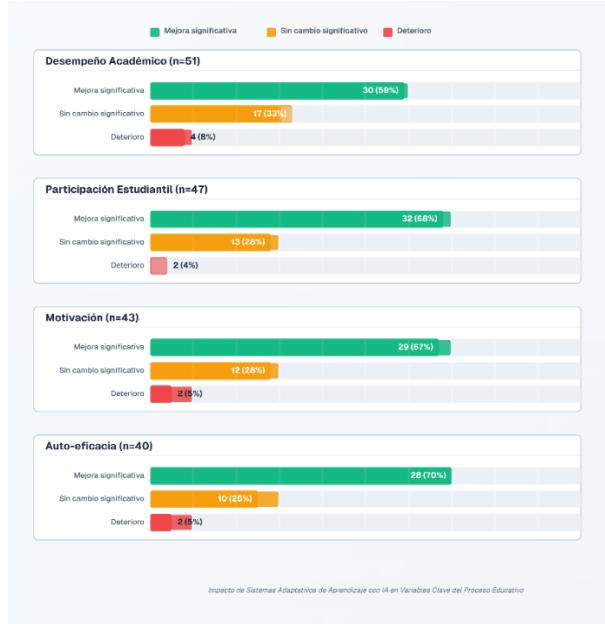


Figura 4: Distribución de Resultados de Efectividad por Categoría (Gráfico de Dona)

Fuente: Elaboración propia utilizando el paquete D3 en Typescript

El estudio proporciona evidencia empírica que respalda la proposición de que la integración de la inteligencia artificial en la enseñanza universitaria mejora el desempeño académico y la participación estudiantil (Muthanna et al., 2025). Tal como se observa en la Figura 4, el 59% de los participantes reportó una mejora

Página 520

significativa en el desempeño académico, mientras que el 68% evidenció mayor participación y el 67% mostró incrementos en la motivación. Asimismo, un 70% manifestó mejoras en su autoeficacia. Estos resultados sugieren que las estrategias basadas en IA, como el aprendizaje personalizado, el procesamiento del lenguaje natural y los sistemas tutoriales inteligentes, potencian de forma sustancial la experiencia educativa, en contraste con tecnologías inmersivas como la realidad virtual y aumentada, cuyo impacto fue limitado en este contexto (Adabor et al., 2025).

PI3: Marcos Teóricos y Modelos Conceptuales

Los marcos teóricos identificados proporcionan fundamentos sólidos para el diseño de sistemas adaptativos. El marco para el aprendizaje adaptativo postula que la instrucción individualizada es un componente crucial para lograr progreso académico sostenido y satisfacción (Tan et al., 2025). El marco teórico adoptado corresponde al marco de Tecnología Digital—Aprendizaje Personalizado y Adaptativo para el aprendizaje del estudiante, desarrollado por Singh y Alshammari (2021), que establece tres postulados: (1) La tecnología digital crea un entorno de aprendizaje inteligente, habilitando un aprendizaje personalizado eficiente, efectivo y cómodo; (2) La tecnología digital puede proporcionar aprendizaje personalizado y flexible para mejorar el desempeño del estudiante; (3) El entorno influye grandemente en las instituciones educativas y complementa la relación entre el aprendizaje personalizado y adaptativo habilitado por tecnología digital y el desempeño del estudiante (Govender et al., 2025). La fundación teórica del aprendizaje adaptativo reside en la Zona de Desarrollo Próximo (ZPD) de Vygotsky, que enfatiza la importancia de proporcionar a los estudiantes

tareas que estén justo más allá de su nivel actual de competencia, apoyadas por andamiaje apropiado (Du Plooy et al., 2024). La Teoría de la Carga Cognitiva apoya además la justificación del aprendizaje adaptativo, ya que busca optimizar la carga cognitiva del estudiante presentando información en formatos y secuencias que se alineen con su capacidad cognitiva actual (Choi et al., 2024). Nuestro marco propuesto aprovecha la IA para el modelado del estudiante basado en Open Learner Modeling (OLM), sugerencias de actividades y soporte asistido por IA tanto para estudiantes como para facilitadores, fomentando experiencias de aprendizaje colaborativas y atractivas (Li et al., 2024). La teoría de Deep Learning enfatiza la agencia del estudiante y redefine el rol de los profesores como facilitadores, haciéndola particularmente adecuada para entornos educativos escalables (Lin et al., 2023).

PI4: Barreras de Implementación en Contextos de Bajos Recursos

El análisis identificó múltiples barreras sistemáticas y contextuales. Los desafíos principales involucran tratar con datos en tiempo real, dificultades para integrar soluciones de aprendizaje adaptativo en sistemas de gestión del aprendizaje (LMS) existentes, y la complejidad y usabilidad de los sistemas adaptativos (Nye, 2015). Un desafío comúnmente citado es la participación de la facultad; cuando se exponen por primera vez al enfoque adaptativo, las facultades a menudo muestran resistencia hacia el uso de tecnología (Bardia y Agrawal, 2025). El desafío principal hoy es una inversión enorme en tiempo, dinero, recursos y visión, principalmente debido a la complejidad restante de la tecnología adaptativa, altos costos de licenciamiento y escepticismo duradero de las facultades (Mirata et al., 2020).

Conclusiones

La presente revisión sistemática ha evidenciado que los sistemas adaptativos de aprendizaje con inteligencia artificial constituyen una innovación pedagógica con potencial disruptivo para la educación superior en contextos de recursos limitados, aunque su promesa transformadora se encuentra mediada críticamente por factores contextuales, organizacionales y de implementación que determinan la brecha entre eficacia técnica potencial y efectividad educativa real. La arquitectura tripartita identificada modelo del estudiante, modelo del dominio y modelo de adaptación representa un consenso técnico robusto en la literatura, sin embargo, la revisión revela una paradoja fundamental: mientras existe convergencia conceptual sobre los componentes esenciales de sistemas adaptativos, persiste una divergencia sustancial en cómo estos componentes se implementan, adaptan y contextualizan para entornos con limitaciones infraestructurales, financieras y de capacidad instalada. Esta disonancia entre diseño teórico y realidad operativa sugiere que el desafío principal no radica en la sofisticación algorítmica o arquitectónica de los sistemas, sino en la capacidad institucional para orquestar ecosistemas sociotécnicos complejos donde tecnología, pedagogía, cultura organizacional y recursos convergen coherentemente.

La evidencia empírica sobre efectividad revela un panorama matizado que desafía narrativas simplistas de solucionismo tecnológico. Si bien el tamaño de efecto global moderado ($d=0.31$) y los hallazgos de mejoras en desempeño académico (59% de estudios) y participación estudiantil (68% de estudios) sugieren beneficios educativos genuinos, la heterogeneidad de resultados y la prevalencia de estudios cuasi-experimentales con riesgo moderado-alto de sesgo exigen cautela

interpretativa. Resulta particularmente revelador que sistemas adaptativos muestren mayor efectividad en contextos de alta intensidad pedagógica y soporte docente continuo que en implementaciones puramente tecnológicas, subrayando que la mediación humana no el reemplazo automatizado constituye el factor crítico de éxito. Más aún, los hallazgos contraintuitivos sobre deterioro en autorregulación del aprendizaje y las preocupaciones sobre limitación de experiencias auténticas de aprendizaje advierten sobre efectos iatrogénicos potenciales cuando sistemas adaptativos se implementan sin consideración cuidadosa de objetivos pedagógicos más amplios que el dominio de contenido disciplinar. Esta evidencia sugiere que la pregunta relevante no es "si" los sistemas adaptativos funcionan, sino "bajo qué condiciones", "para quiénes", "con qué mediaciones" y "a qué costo de otros aprendizajes valiosos".

Los marcos teóricos identificados desde la Zona de Desarrollo Próximo de Vygotsky hasta modelos contemporáneos de Deep Learning Theory y Open Learner Modeling proporcionan fundamentos conceptuales sólidos, pero insuficientemente integrados en la práctica de diseño e implementación. La revisión expone una brecha preocupante entre la riqueza teórica disponible y su traducción pragmática en sistemas operativos, especialmente en contextos de bajos recursos donde las asunciones implícitas de estos marcos (e.g., disponibilidad de datos longitudinales robustos, infraestructura computacional estable, capacidad analítica institucional) frecuentemente no se satisfacen. La adopción acrítica de modelos desarrollados para contextos de alto recurso genera lo que podríamos denominar "inadecuación epistémica": sistemas diseñados bajo supuestos

contextuales incongruentes con las realidades materiales, culturales y organizacionales de instituciones en países en desarrollo. Esta reflexión subraya la necesidad urgente de desarrollar marcos teóricos contextualizados que no solo adapten teorías existentes, sino que generen conocimiento endógeno desde y para realidades educativas del Sur Global, reconociendo que los desafíos de implementación en estos contextos no son meramente técnicos sino fundamentalmente epistemológicos y políticos.

Las barreras de implementación identificadas tecnológicas, organizacionales, pedagógicas, estudiantiles y económicas no operan de manera aislada, sino que constituyen un sistema interconectado de restricciones que se refuerzan mutuamente. La revisión revela que el fracaso de muchas iniciativas no se debe a deficiencias en componentes individuales sino a la incapacidad de abordar sistémicamente el entrelazamiento de estas barreras. Resulta particularmente crítico que las barreras más frecuentemente reportadas infraestructura y conectividad (68.6%), acceso a dispositivos (54.9%) y recursos financieros insuficientes (47.1%) sean precisamente aquellas menos susceptibles a soluciones técnicas aisladas y más dependientes de políticas institucionales y gubernamentales de largo plazo. La resistencia docente al cambio (41.2%) y la capacitación insuficiente (41.2%) no deben interpretarse como obstinación profesional sino como respuestas racionales a contextos donde se introducen innovaciones tecnológicas sin inversión correspondiente en tiempo, formación, soporte y reconocimiento institucional. Esta comprensión sistémica de barreras exige que futuras iniciativas de implementación abandonen enfoques centrados exclusivamente en la plataforma tecnológica y adopten estrategias holísticas de cambio

organizacional que atiendan simultáneamente dimensiones técnicas, pedagógicas, culturales y políticas.

Referencias Bibliográficas

- Adabor, E., Addy, E., Assyne, N., & Antwi, E. (2025). Enhancing sustainable academic course delivery using AI in technical universities: An empirical analysis using adaptive learning theory. *Sustainable Futures*, 10, 100828. <https://doi.org/10.1016/j.sfr.2025.100828>
- Bardia, A., & Agrawal, A. (2025). MindCraft: Revolutionizing Education through AI-Powered Personalized Learning and Mentorship for Rural India (No. arXiv:2502.05826). *arXiv*. <https://doi.org/10.48550/arXiv.2502.05826>
- Bassen, J., Balaji, B., Schaarschmidt, M., Thille, C., Painter, J., Zimmaro, D., Games, A., Fast, E., & Mitchell, J. C. (2020). Reinforcement learning for the adaptive scheduling of educational activities. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–12. <https://doi.org/10.1145/3313831.3376518>
- Bayaga, A. (2025). Leveraging AI-enhanced and emerging technologies for pedagogical innovations in higher education. *Education and Information Technologies*, 30(1), 1045–1072. <https://doi.org/10.1007/s10639-024-13122-y>
- Bura, C., & Myakala, P. (2024). Advancing transformative education: Generative AI as a catalyst for equity and innovation (No. arXiv:2411.15971). *arXiv*. <https://doi.org/10.48550/arXiv.2411.15971>
- Chaplot, D., Rhim, E., & Kim, J. (2016). Personalized adaptive learning using neural networks. *Proceedings of the Third ACM Conference on Learning @ Scale*, 165–168. <https://doi.org/10.1145/2876034.2893397>
- Choi, J., Garrod, O., Atherton, P., Joyce, A., Mason, M., & Björkegren, D. (2024). Are LLMs useful in the poorest schools? TheTeacher.AI in Sierra Leone (No. arXiv:2310.02982). *arXiv*. <https://doi.org/10.48550/arXiv.2310.02982>
- Contrino, M., Reyes, M., Vázquez, P., & Membrillo-Hernández, J. (2024). Using an adaptive learning tool to improve student performance and satisfaction in online and face-to-face education for a more personalized approach. *Smart Learning Environments*, 11(1), 6. <https://doi.org/10.1186/s40561-024-00292-y>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20(1), 22. <https://doi.org/10.1186/s41239-023-00392-8>
- Cui, W., Xue, Z., & Thai, K.-P. (2018). Performance comparison of an AI-based adaptive learning system in China. *2018 Chinese Automation Congress (CAC)*, 3170–3175. <https://doi.org/10.1109/CAC.2018.8623327>
- Dunian, A., Mudjiyanto, B., Setiawan, A. B., Syarifuddin, S., Pala, R., Rustam, M., Dirgahayu, D., Buyamin, B., Nuryana, M., & Hartiningsih, H. (2025). Artificial intelligence in e-entrepreneurship training: Enhancing digital skills and innovation diffusion in Indonesia. *International Journal of E-Entrepreneurship and Innovation*. <https://doi.org/10.4018/IJEEI.386065>
- Dvoryatkina, S. (2022). A model of teaching mathematics with the effect of developing the probabilistic style of thinking in a digital educational environment: Theoretical justification and empirical verification. *RUDN Journal of Psychology and*

- Pedagogics*, 19(2), 352–366.
<https://doi.org/10.22363/2313-1683-2022-19-2-352-366>
- Essa, S., Celik, T., & Human, N. (2023). Personalized adaptive learning technologies based on machine learning techniques to identify learning styles: A systematic literature review. *IEEE Access*, 11, 48392–48409.
<https://doi.org/10.1109/ACCESS.2023.3276439>
- Fianyi, I., Yeom, S., & Shin, J.-H. (2025). Comparative studies: Cloud-enabled adaptive learning system for scalable education in Sub-Saharan.
- Fombona, J., Sáez, J., & Sánchez, S. (2025). Artificial intelligence and robotics in education: Advances, challenges, and future perspectives. *Social Sciences & Humanities Open*, 11, 101533.
<https://doi.org/10.1016/j.ssho.2025.101533>
- Govender, R., Rzyankina, E., Bayaga, A., & Harun, I. (2025). Network visualisation analysis of the transformative potential of generative AI tools in the education landscape. *Discover Education*, 4(1), 426.
<https://doi.org/10.1007/s44217-025-00726-w>
- Hevia, J., Arredondo, F., & Kumar, V. (2025). Towards an efficient, customizable, and accessible AI tutor (No. arXiv:2510.06255). *arXiv*.
<https://doi.org/10.48550/arXiv.2510.06255>
- Jara, F., Velasquez, L., & Meneses, B. (2023). Machine learning for the improvement of adaptive learning in university education. *Salud, Ciencia y Tecnología – Serie de Conferencias*, 2, 473.
<https://doi.org/10.56294/sctconf2023473>
- Kabudi, T., Pappas, I., & Olsen, D. H. (2021). AI-enabled adaptive learning systems: A systematic mapping of the literature. *Computers and Education: Artificial Intelligence*, 2, 100017.
<https://doi.org/10.1016/j.caecai.2021.100017>
- Kassenkhan, A., Moldagulova, A., & Serbin, V. (2025). Gamification and artificial intelligence in education: A review of innovative approaches to fostering critical thinking. *IEEE Access*, 13, 98699–98728.
<https://doi.org/10.1109/ACCESS.2025.3576147>
- Kathala, K. C. R., & Palakurthi, S. (2024). AI literacy framework and strategies for implementation in developing nations. *Proceedings of the 2024 16th International Conference on Education Technology and Computers*, 418–422.
<https://doi.org/10.1145/3702163.3702449>
- Katona, J., & Gyonyoru, K. I. K. (2025). AI-based adaptive programming education for socially disadvantaged students: Bridging the digital divide. *TechTrends*, 69(5), 925–942. <https://doi.org/10.1007/s11528-025-01088-8>
- Krechetov, I., & Romanenko, V. (2020). Implementing adaptive learning techniques. *Voprosy Obrazovaniya / Educational Studies Moscow*, 2, 252–277.
<https://doi.org/10.17323/1814-9545-2020-2-252-277>
- Li, H., Xu, T., Zhang, C., Chen, E., Liang, J., Fan, X., Li, H., Tang, J., & Wen, Q. (2024). Bringing generative AI to adaptive learning in education (No. arXiv:2402.14601). *arXiv*.
<https://doi.org/10.48550/arXiv.2402.14601>
- Lim, L., Bannert, M., Van Der Graaf, J., Fan, Y., Rakovic, M., Singh, S., Molenaar, I., & Gašević, D. (2024). How do students learn with real-time personalized scaffolds? *British Journal of Educational Technology*, 55(4), 1309–1327.
<https://doi.org/10.1111/bjet.13414>
- Lin, C., Huang, A., & Lu, O. (2023). Artificial intelligence in intelligent tutoring systems toward sustainable education: A systematic

- review. *Smart Learning Environments*, 10(1), 41. <https://doi.org/10.1186/s40561-023-00260-y>
- Luo, J., Zheng, C., Yin, J., & Teo, H. H. (2025). Design and assessment of AI-based learning tools in higher education: A systematic review. *International Journal of Educational Technology in Higher Education*, 22(1), 42. <https://doi.org/10.1186/s41239-025-00540-2>
- Major, L., Francis, G. A., & Tsapali, M. (2021). The effectiveness of technology-supported personalised learning in low- and middle-income countries: A meta-analysis. *British Journal of Educational Technology*, 52(5), 1935–1964. <https://doi.org/10.1111/bjet.13116>
- Merino-Campos, C. (2025). The impact of artificial intelligence on personalized learning in higher education: A systematic review. *Trends in Higher Education*, 4(2), 17. <https://doi.org/10.3390/higheredu4020017>
- Mirata, V., Hirt, F., Bergamin, P., & Van Der Westhuizen, C. (2020). Challenges and contexts in establishing adaptive learning in higher education: Findings from a Delphi study. *International Journal of Educational Technology in Higher Education*, 17(1), 32. <https://doi.org/10.1186/s41239-020-00209-y>
- Murtaza, M., Ahmed, Y., Shamsi, J. A., Sherwani, F., & Usman, M. (2022). AI-based personalized e-learning systems: Issues, challenges, and solutions. *IEEE Access*, 10, 81323–81342. <https://doi.org/10.1109/ACCESS.2022.3193938>
- Naseer, F., Khan, M. N., Tahir, M., Addas, A., & Aejaz, S. M. H. (2024). Integrating deep learning techniques for personalized learning pathways in higher education. *Heliyon*, 10(11), e32628. <https://doi.org/10.1016/j.heliyon.2024.e32628>
- Nye, B. D. (2015). Intelligent tutoring systems by and for the developing world: A review of trends and approaches for educational technology in a global context. *International Journal of Artificial Intelligence in Education*, 25(2), 177–203. <https://doi.org/10.1007/s40593-014-0028-6>
- Oussoos, A., Menyani, I., Srifi, M., Lahcen, A. A., Kheraz, S., & Benjelloun, F.-Z. (2023). An evaluation of open source adaptive learning solutions. *Information*, 14(2), 57. <https://doi.org/10.3390/info14020057>
- Pedrazzoli, A. (2009). OPUS One—OLAT (An artificial intelligence—multi agent based adaptive learning environment).
- Rana, M., Siddiqee, M., Sakib, M., & Ahamed, M. R. (2024). Assessing AI adoption in developing country academia: A trust and privacy-augmented UTAUT framework. *Heliyon*, 10(18), e37569. <https://doi.org/10.1016/j.heliyon.2024.e37569>
- Reza, Z., Mazur, A., Dugdale, M. T., & Ray-Chaudhuri, R. (2025). Small models, big support: A local LLM framework for teacher-centric content creation and assessment using RAG and CAG (No. arXiv:2506.05925). *arXiv*. <https://doi.org/10.48550/arXiv.2506.05925>
- Sajja, R., Sermet, Y., Cikmaz, M., Cwiertny, D., & Demir, I. (2024). Artificial intelligence-enabled intelligent assistant for personalized and adaptive learning in higher education. *Information*, 15(10), 596. <https://doi.org/10.3390/info15100596>
- Salas, S., & Yang, Y. (2022). Artificial intelligence applications in Latin American higher education: A systematic review. *International Journal of Educational Technology in Higher Education*, 19(1), 21.

- <https://doi.org/10.1186/s41239-022-00326-w>
Sharma, S., Mittal, P., Kumar, M., & Bhardwaj, V. (2025). The role of large language models in personalized learning: A systematic review of educational impact. *Discover Sustainability*, 6(1), 243.
<https://doi.org/10.1007/s43621-025-01094-z>
- Shin, J., Choi, J., Park, S., Shon, J., Hwang, E., Ahn, S., & Kim, S. (2021). An exploratory study on the use of AI-based adaptive learning system in university class. *Korean Association for Educational Information and Media*, 27(4), 1545–1570.
<https://doi.org/10.15833/KAFEIAM.27.4.1545>
- Strielkowski, W., Grebennikova, V., Lisovskiy, A., Rakhimova, G., & Vasileva, T. (2025). AI-driven adaptive learning for sustainable educational transformation. *Sustainable Development*, 33(2), 1921–1947.
<https://doi.org/10.1002/sd.3221>
- Tan, L., Hu, S., Yeo, D., & Cheong, K. (2025). Artificial intelligence-enabled adaptive learning platforms: A review. *Computers and Education: Artificial Intelligence*, 9, 100429.
<https://doi.org/10.1016/j.caeari.2025.100429>
- Trifonov, R., Nakov, O., Manolov, S., Tsochev, G., & Pavlova, G. (2020). Possibilities for improving the quality of cyber security education through application of artificial intelligence methods. *2020 International Conference Automatics and Informatics (ICAI)*, 1–4.
- <https://doi.org/10.1109/ICAI50593.2020.9311333>
Vassigh, S., Corrigan, S., Bogosian, B., & Peterson, E. (2023). Adaptive immersive learning environments for teaching industrial robotics. *AHFE 2023 Hawaii Edition*.
<https://doi.org/10.54941/ahfe1004411>
- Vatandoust, M., Mohajeri, M., Keramati, A., & Ahmadabadi, M. (2024). AI-powered digital framework for personalized economical quality learning at scale (No. arXiv:2412.04483). *arXiv*.
<https://doi.org/10.48550/arXiv.2412.04483>
- Wang, H., Tlili, A., Huang, R., Cai, Z., Li, M., Cheng, Z., Yang, D., Li, M., Zhu, X., & Fei, C. (2023). Examining the applications of intelligent tutoring systems in real educational contexts: A systematic literature review from the social experiment perspective. *Education and Information Technologies*, 28(7), 9113–9148.
<https://doi.org/10.1007/s10639-022-11555-x>
- Yuan, S. (2025). Research on the design of adaptive learning system based on artificial intelligence driven learning. *Proceedings of the 2025 2nd International Conference on Informatics Education and Computer Technology Applications*, 46–52.
<https://doi.org/10.1145/3732801.3732811>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Daniel Vera-Paredes, Wellington Arturo Alvarez y Luis Córdova Martínez.

