

Estrategias pedagógicas mediadas por IA para la personalización del aprendizaje en educación básica

AI-mediated pedagogical strategies for personalizing learning in basic education

Estratégias pedagógicas mediadas por IA para a personalização da aprendizagem no ensino básico

Castillo Tigasi, María José

Investigador Independiente

majitocastillo1@hotmail.com

<https://orcid.org/0009-0002-0773-8262>



Chango Pila, Jessica Elizabeth

Investigador Independiente

jessicachangopila@gmail.com

<https://orcid.org/0009-0003-4492-5208>



Tipanluisa Cando, Miryam Esthela

Investigador Independiente

esthetipan@gmail.com

<https://orcid.org/0009-0007-2790-5714>



Mendaño Yanchapanta, María Manuela

Investigador Independiente

maria.mendano@educacion.gob.ec

<https://orcid.org/0009-0003-3633-9647>



González Quezada, Katherine Vanessa

Investigador Independiente

katherinev.gonzalez@gmail.com

<https://orcid.org/0009-0008-8351-7529>



DOI / URL: <https://doi.org/10.55813/gaea/ccri/v6/n2/1252>

Como citar:

Castillo Tigasi, M. J., Chango Pila, J. E., Tipanluisa Cando, M. E., Mendaño Yanchapanta, M. M., & González Quezada, K. V. (2025). Estrategias pedagógicas mediadas por IA para la personalización del aprendizaje en educación básica. *Código Científico Revista De Investigación*, 6(2), 1473–1490.

Recibido: 28/11/2025

Aceptado: 18/12/2025

Publicado: 31/12/2025

Resumen

La incorporación acelerada de la inteligencia artificial en la educación básica reaviva la dificultad de atender ritmos y necesidades heterogéneas con tiempo docente limitado; este estudio examina estrategias pedagógicas mediadas por esta tecnología para personalizar contenidos, andamiaje y evaluación. Se realizó una revisión exploratoria de alcance de literatura indexada entre 2011 y febrero de 2026, mediante búsquedas en bases de datos, criterios de elegibilidad explícitos, cribado por doble revisión y síntesis narrativa. Los hallazgos evidencian mejoras consistentes en aprendizaje y participación frente a enfoques no adaptativos cuando la personalización se sustenta en diagnóstico fino, secuenciación adaptativa y retroalimentación oportuna, alineadas con el currículo y la evaluación formativa. También se identifican riesgos de sesgo y tensiones de privacidad que requieren gobernanza de datos, auditorías de equidad y diseño centrado en docentes y estudiantes. Se concluye que estas estrategias son más efectivas y sostenibles cuando amplifican la mediación docente mediante analíticas accionables, desarrollo profesional y despliegues graduales de bajo riesgo.

Palabras clave: inteligencia artificial educativa; aprendizaje personalizado; analítica del aprendizaje; tutoría inteligente; equidad educativa.

Abstract

The accelerated incorporation of artificial intelligence into basic education revives the difficulty of addressing heterogeneous rhythms and needs with limited teaching time; this study examines pedagogical strategies mediated by this technology to personalize content, scaffolding, and assessment. An exploratory review of indexed literature between 2011 and February 2026 was conducted using database searches, explicit eligibility criteria, double-blind screening, and narrative synthesis. The findings show consistent improvements in learning and participation compared to non-adaptive approaches when personalization is based on fine-grained diagnosis, adaptive sequencing, and timely feedback, aligned with the curriculum and formative assessment. Risks of bias and privacy tensions are also identified, requiring data governance, equity audits, and teacher- and student-centered design. It is concluded that these strategies are most effective and sustainable when they amplify teacher mediation through actionable analytics, professional development, and gradual, low-risk deployments.

Keywords: educational artificial intelligence; personalized learning; learning analytics; intelligent tutoring; educational equity.

Resumo

A incorporação acelerada da inteligência artificial na educação básica reaviva a dificuldade de atender a ritmos e necessidades heterogêneas com tempo docente limitado; este estudo examina estratégias pedagógicas mediadas por essa tecnologia para personalizar conteúdos, andaimes e avaliações. Foi realizada uma revisão exploratória da literatura indexada entre 2011 e fevereiro de 2026, por meio de pesquisas em bases de dados, critérios de elegibilidade explícitos, triagem por dupla revisão e síntese narrativa. Os resultados evidenciam melhorias consistentes na aprendizagem e participação em comparação com abordagens não adaptativas quando a personalização se baseia em diagnósticos precisos, sequenciamento adaptativo e feedback oportuno, alinhados com o currículo e a avaliação formativa. Também são identificados riscos de viés e tensões de privacidade que exigem governança de dados, auditorias de equidade e design centrado em professores e alunos. Conclui-se que estas estratégias são mais eficazes e

sustentáveis quando amplificam a mediação docente por meio de análises acionáveis, desenvolvimento profissional e implementações graduais de baixo risco.

Palavras-chave: inteligência artificial educacional; aprendizagem personalizada; análise da aprendizagem; tutoria inteligente; equidade educacional.

Introducción

La acelerada incorporación de la inteligencia artificial (IA) en educación básica reaviva un problema persistente: la dificultad de atender la heterogeneidad de ritmos, trayectorias y necesidades en aulas numerosas con tiempo docente limitado. La personalización del aprendizaje —ajustar contenido, andamiaje y evaluación al perfil de cada estudiante— ha mostrado ser una vía potente, pero su implementación sostenida ha estado restringida por recursos y por la complejidad de tomar decisiones didácticas finamente calibradas en tiempo real. La literatura reciente sugiere que las estrategias pedagógicas mediadas por IA, como los tutores inteligentes, las plataformas adaptativas y la analítica del aprendizaje, pueden ofrecer apoyos equivalentes a la tutoría individual a escala, con mejoras de logro frente a la instrucción tradicional y a otras tecnologías no adaptativas (Ma et al., 2014; VanLehn, 2011; Fletcher & Kulik, 2016).

Ahora bien, el problema no es únicamente tecnológico. En educación básica, la “personalización” enfrenta factores y afectaciones que trascienden el rendimiento académico: desigualdades de acceso, riesgos de sesgos algorítmicos que reproduzcan brechas, opacidad de modelos, y tensiones con la privacidad y el control docente. La evidencia revisada en educación con IA documenta manifestaciones de sesgo en sistemas de recomendación, predicción de riesgo y calificación automatizada, con implicaciones de justicia para grupos históricamente subatendidos (Baker & Hawn, 2021). A ello se suma que muchos despliegues priorizan la automatización sin involucrar a docentes y estudiantes en el diseño, lo que merma confianza y alineación pedagógica (Alfredo et al., 2024). La analítica del aprendizaje, piedra angular de la personalización, exige salvaguardas para el tratamiento de datos estudiantiles y la reducción de errores y sesgos, so pena de generar diagnósticos inexactos o usos no transparentes (Khor &

Mutthulakshmi, 2024). En este contexto, la necesidad no es “usar IA”, sino delimitar condiciones didácticas, éticas y organizacionales que permitan estrategias pedagógicas mediadas por IA centradas en el bienestar y la equidad del estudiantado de educación básica.

La justificación y viabilidad de una revisión bibliográfica focalizada en “estrategias pedagógicas mediadas por IA para la personalización” descansa en tres pilares. Primero, existe masa crítica de pruebas de eficacia: meta-análisis y revisiones muestran efectos positivos de los sistemas de tutoría inteligente frente a clases tradicionales y a software no adaptativo; en promedio, los tamaños de efecto oscilan entre $g \approx 0.41$ en términos globales y ventajas específicas frente a instrucción grupal y materiales estáticos (Ma et al., 2014; Fletcher & Kulik, 2016; VanLehn, 2011). Asimismo, estudios experimentales en etapas tempranas de escolaridad reportan ganancias de aprendizaje con recursos adaptativos orientados a matemáticas, lo que sugiere aplicabilidad directa a educación básica (Bang et al., 2023). Segundo, la viabilidad tecnológica ha madurado: las plataformas adaptativas basadas en IA ajustan rutas, nivel de dificultad y retroalimentación mediante modelos de estudiante y técnicas de recomendación; revisiones recientes sintetizan sus fundamentos y retos de despliegue en contextos reales (Tan, Hu, Yeo, & Cheong, 2025; Wang et al., 2024). Tercero, se reconoce la centralidad del profesorado: integrar IA con sentido pedagógico exige desarrollo profesional, nuevas prácticas de evaluación formativa y gobernanza de datos; la literatura sistematiza necesidades docentes y brechas de formación para una adopción responsable (Tan, Cheng, & Ling, 2025) y propone marcos de diseño centrados en las personas para equilibrar control humano y automatización (Alfredo et al., 2024).

Con base en lo anterior, esta revisión se propone un objetivo claro: examinar críticamente la evidencia reciente y de alta calidad indexada (Scopus/WoS) sobre estrategias pedagógicas mediadas por IA que habilitan la personalización del aprendizaje en educación básica, articulando (a) qué enfoques muestran mayor efectividad (p. ej., tutores inteligentes,

plataformas adaptativas, analítica del aprendizaje en aula), (b) bajo qué condiciones didácticas y de implementación resultan viables y éticamente responsables (gobernanza de datos, mitigación de sesgos, rol docente), y (c) qué lagunas persisten para orientar futuras investigaciones y políticas de escala. El propósito último es ofrecer lineamientos accionables —anclados en pruebas y en principios de diseño centrado en estudiantes y docentes— para que escuelas de educación básica incorporen IA no como fin, sino como medio para avanzar en trayectorias personalizadas, oportunas y equitativas. (Khor & Mutthulakshmi, 2024; Baker & Hawn, 2021).

Metodología

Se llevó a cabo una revisión exploratoria de la literatura con enfoque de alcance, orientada a mapear y sintetizar la evidencia disponible sobre estrategias pedagógicas mediadas por IA que posibilitan la personalización del aprendizaje en educación básica. El proceso metodológico se diseñó para maximizar transparencia, reproducibilidad y cobertura temática, combinando procedimientos sistematizados de búsqueda, cribado, evaluación de calidad y síntesis narrativa. La pregunta guía se definió así: “¿Qué enfoques, condiciones de implementación y resultados reporta la literatura indexada sobre estrategias pedagógicas mediadas por IA para personalizar el aprendizaje en educación básica?” A partir de esta pregunta se operacionalizaron términos clave y criterios de elegibilidad, y se elaboró un protocolo previo que especificó fuentes de información, operadores de búsqueda, procedimientos de doble revisión, variables de extracción y plan de análisis. El periodo de interés se acotó entre enero de 2011 y febrero de 2026 para capturar el desarrollo contemporáneo de la IA educativa; se incluyeron publicaciones en español e inglés con texto completo accesible.

La búsqueda bibliográfica se ejecutó principalmente en bases de datos indexadas y de alta cobertura disciplinar: Scopus y Web of Science para el rastreo transversal, y ERIC, IEEE Xplore y ACM Digital Library para recuperar estudios pedagógicos y tecnológicos relevantes. Como estrategia de sensibilidad y especificidad, se combinaron términos controlados y palabras clave libres, con uso de operadores booleanos, truncamientos y proximidad. Ejemplos de cadenas maestras (ajustadas a cada base) fueron: (“intelligent tutoring system*” OR “adaptive learning” OR “learning analytic*” OR “educational recommender*” OR “AI in education”) AND (“personalized learning” OR personalisation OR “differentiated instruction”) AND (“primary education” OR “elementary school” OR “K-12”); y su contraparte en español: (“tutoría inteligente” OR “aprendizaje adaptativo” OR “analítica del aprendizaje” OR “recomendadores educativos” OR “IA en educación”) AND (“aprendizaje personalizado” OR “personalización” OR “diferenciación pedagógica”) AND (“educación básica” OR “educación primaria” OR “escuela básica”). Para ampliar la cobertura se aplicó “snowballing” hacia atrás y hacia adelante (revisión de referencias citadas y de citas recibidas) y se realizaron búsquedas complementarias por autor y por revista en títulos especializados del campo. Los registros se gestionaron en un gestor bibliográfico para depurar duplicados antes del cribado.

Los criterios de inclusión contemplaron estudios empíricos (cuasi-experimentales, experimentales, de implementación o de métodos mixtos), revisiones sistemáticas o de alcance, y marcos de diseño con validación en aula que: (a) abordaran explícitamente la personalización del aprendizaje mediada por IA; (b) se desarrollaran en contextos de educación básica (primaria o niveles K-6/K-8, incluyendo programas extracurriculares escolarizados); y (c) reportaran resultados de aprendizaje, participación, equidad, carga docente o condiciones de implementación. Se excluyeron artículos de opinión, notas técnicas sin evaluación en contextos escolares, tesis no indexadas, estudios centrados exclusivamente en educación superior sin extrapolación a básica, intervenciones no mediadas por IA (p. ej., plataformas estáticas), y

publicaciones sin acceso a texto completo o sin información metodológica suficiente. Dos revisores entrenados aplicaron de manera independiente los criterios de elegibilidad en dos fases (título/resumen y texto completo), con resolución de discrepancias por consenso o por un tercer revisor. Se documentó el flujo de registros identificados, incluidos, excluidos y con razones de exclusión, siguiendo un diagrama de proceso estándar para revisiones.

La evaluación de calidad y riesgo de sesgo se efectuó según la naturaleza del estudio. Para diseños experimentales y cuasi-experimentales se valoraron la aleatorización, equivalencia de grupos, cegamiento, integridad de datos y selectividad de reportes; en estudios observacionales se consideraron la validez interna, control de confusores y claridad de la medición; en revisiones secundarias se verificaron la exhaustividad de la búsqueda, la transparencia del protocolo y la evaluación crítica de los estudios primarios. Los instrumentos de referencia se adaptaron para asegurar consistencia entre revisores y se registraron puntuaciones y juicios cualitativos, sin excluir estudios únicamente por calidad cuando aportaban información contextual relevante, pero ponderando su peso en la síntesis.

La extracción de datos se realizó con una plantilla previamente pilotada que incluyó: identificación bibliográfica; país y contexto escolar; nivel y área curricular; características de la muestra; tipo de tecnología y aproximación de IA (p. ej., tutores inteligentes, plataformas adaptativas, analítica del aprendizaje, agentes conversacionales); mecanismo de personalización (modelado de estudiante, recomendación de contenidos, retroalimentación adaptativa, agrupamiento dinámico); rol docente e integración curricular; diseño y duración de la intervención; métricas de resultado (rendimiento, progreso, participación, equidad, carga cognitiva, percepción docente/estudiantil); recursos e infraestructura; consideraciones éticas y de gobernanza de datos; y limitaciones señaladas. La extracción fue doble e independiente en una submuestra para asegurar confiabilidad interevaluador y luego continuó con verificación cruzada.

Dada la heterogeneidad esperada en tecnologías, contextos y métricas, se optó por una síntesis narrativa y una tematización inductivo-deductiva. En una primera etapa se codificaron unidades de significado alineadas con la pregunta guía y los constructos del protocolo; en una segunda, se agruparon códigos en categorías analíticas (p. ej., “eficacia sobre rendimiento”, “condiciones de implementación”, “equidad y sesgos”, “desarrollo profesional docente”, “sostenibilidad y escalabilidad”). Cuando fue metodológicamente defendible, se calcularon efectos estandarizados a partir de estadísticos reportados para ofrecer referencias comparables, sin realizar metaanálisis agregados debido a la variabilidad en diseños y resultados. Se desarrollaron mapas de evidencia para visualizar densidades temáticas y vacíos de investigación.

Para asegurar transparencia y reproducibilidad, se registró el protocolo, se preservaron las cadenas de búsqueda exactas por base de datos, se documentaron decisiones de cribado y evaluación, y se archivaron la matriz de extracción y el esquema de codificación en un repositorio abierto. Al no involucrar interacción directa con seres humanos ni datos sensibles a nivel individual, no fue necesaria aprobación ética; no obstante, se observaron criterios de integridad académica y de uso responsable de la información. El resultado de este procedimiento es una cartografía crítica de las estrategias pedagógicas mediadas por IA en educación básica, sus condiciones de viabilidad y sus efectos reportados, que fundamenta las conclusiones y recomendaciones del artículo.

Resultados

Efectividad y condiciones de implementación de estrategias pedagógicas mediadas por IA para la personalización en educación básica

Efectos en el aprendizaje y la participación estudiantil

La evidencia de mayor jerarquía (síntesis cuantitativas y revisiones de alcance) respalda que la personalización algorítmica logra incrementos de rendimiento y compromiso estudiantil frente a comparadores no adaptativos o instrucción masiva. En el metaanálisis de Ma, Adesope, Nesbit y Liu (2014), que integró 107 tamaños de efecto con 14 321 participantes, los sistemas de tutoría inteligente (STI) superaron de manera consistente a la instrucción tradicional en gran grupo y a software no adaptativo ($g \approx 0,42$ y $g \approx 0,57$, respectivamente), y no difirieron significativamente de formatos de tutoría individual o en pequeños grupos, lo que sugiere que la IA puede aproximar beneficios típicos de la atención uno-a-uno a escala. Estos resultados —observados en primaria y secundaria, y en dominios como matemáticas, lectura y ciencias— no se reducen a “efecto novedad”: emergen cuando el sistema densifica ciclos de práctica-retroalimentación y regula dinámicamente la dificultad, manteniendo al estudiante en su zona óptima de desafío y sosteniendo indicadores de participación como tiempo en tarea y persistencia. (Ma et al., 2014).

Ahora bien, los tamaños de efecto no son invariantes: dependen de la calidad del acoplamiento con el currículo, de la precisión diagnóstica del sistema y del grado en que la retroalimentación se ofrece al nivel de paso o subpaso de la tarea. La comparación integradora de VanLehn (2011) es elocuente: los STI con granularidad fina (step-based/substep-based) alcanzan magnitudes de aprendizaje cercanas a la tutoría humana ($d \approx 0,76$ frente a $d \approx 0,79$), mientras que los entornos “respuesta-a-respuesta” (answer-based) rinden menos. En aulas de educación básica, ello se traduce en ventajas cuando el andamiaje es oportuno, específico y graduado, y cuando las decisiones adaptativas están alineadas con metas de evaluación formativa. (VanLehn, 2011).

Mecanismos de personalización y diseño instruccional

Los efectos anteriores se explican por tres engranajes didácticos: (a) modelado del estudiante, que estima dominio y probabilidad de acierto por habilidad para decidir qué

practicar y cuándo intervenir; (b) recomendación y secuenciación adaptativa, que orchestra rutas idiosincrásicas (diagnóstico → prescripción → evaluación) en congruencia con objetivos curriculares; y (c) retroalimentación adaptativa a nivel de paso, que corrige errores en el momento preciso y previene la sobreasistencia o la frustración. Cuando estos mecanismos se operacionalizan con granularidad suficiente y se encadenan a prácticas de evaluación formativa, los STI y plataformas adaptativas alcanzan efectos comparables a la tutoría humana media; si la adaptación es superficial, opaca o desalineada del currículo, los beneficios decrecen. En suma, no basta con adaptar: la personalización eficaz exige granularidad, trazabilidad y criterio pedagógico en cada decisión algorítmica. (Ma et al., 2014; VanLehn, 2011).

Equidad, sesgos y protección de datos

El mismo andamiaje que mejora el aprendizaje puede amplificar disparidades si los datos y modelos no representan la diversidad estudiantil o si se despliegan sin garantías de justicia. Baker y Hawn (2022) sistematizan manifestaciones de sesgo en educación por raza/etnia, género, nacionalidad, estatus socioeconómico o discapacidad, y mapean los puntos de inyección del sesgo a lo largo del ciclo de vida del sistema (formulación del problema, recopilación/rotulado, modelado, despliegue y uso). Su propuesta de avanzar de la “equidad formal” (paridad de métricas) hacia una equidad sustantiva focalizada en impactos diferenciales por subgrupos conlleva auditorías periódicas, métricas de equidad apropiadas al contexto, trazabilidad de decisiones y rediseño socio-técnico con participación de docentes y comunidades escolares. (Baker & Hawn, 2022).

En paralelo, la personalización guiada por analítica del aprendizaje exige salvaguardas robustas de privacidad y gobernanza de datos. Slade y Prinsloo (2013) proponen un marco de seis principios —que incluyen aprendizaje analítico como práctica moral, consentimiento informado, minimización y de-identificación, transparencia y reciprocidad— para equilibrar

los beneficios pedagógicos con la protección de derechos en contextos educativos. Para educación básica, donde las decisiones algorítmicas inciden tempranamente en trayectorias académicas, el umbral aceptable no es solo la conformidad legal, sino la justificación pedagógica de cada captura y uso de datos, con mecanismos asequibles de explicación, objeción y reparación. (Slade & Prinsloo, 2013).

Rol docente, adopción y sostenibilidad

La evidencia empírica sugiere que el binomio docente-IA supera a cualquiera de sus componentes aislados cuando se articula la complementariedad correcta: la IA como infraestructura de diagnóstico y recomendación; el profesorado como agente de interpretación, mediación y evaluación. Holstein, McLaren y Aleven (2019) muestran —mediante co-diseño y pruebas en aula K-12— que herramientas de analítica en tiempo real, portadas por el profesorado, incrementan la capacidad de orquestación (identificación de errores persistentes, desatención o estancamiento), siempre que las interfaces prioricen explicabilidad para la docencia (por qué se recomienda esto, con qué evidencia, y bajo qué umbral) y mantengan control humano sobre alertas y umbrales. Esto habilita respuestas pedagógicas más finas (reagrupamientos dinámicos, ajustes de andamiaje, intervenciones just-in-time) y refuerza la agencia profesional. (Holstein, McLaren, & Aleven, 2019).

Para que esta promesa sea sostenible a escala escolar, se requieren condiciones organizacionales y de política: (i) desarrollo profesional continuo para leer, cuestionar y aprovechar evidencias algorítmicas en evaluación formativa; (ii) alineación curricular que evite la disonancia entre lo que optimiza la plataforma y lo que valora la escuela; y (iii) gobernanza de datos que legitime prácticas responsables y auditables (p. ej., acuerdos claros de finalidad, retención y acceso). El resultado no es sustituir al docente, sino amplificar su alcance con diagnóstico granular y bucles de mejora continua, manteniendo la responsabilidad última de las decisiones pedagógicas en manos humanas. (Holstein et al., 2019; VanLehn, 2011).

Discusión

Los hallazgos sintetizados permiten discutir, con mirada crítica, el alcance y los límites de la personalización mediada por IA en educación básica. En primer lugar, los efectos positivos sobre el rendimiento y la participación parecen robustos siempre que la IA opere como un amplificador de la evaluación formativa y no como un sustituto de la mediación docente. La evidencia acumulada en metaanálisis sugiere que, frente a la instrucción masiva o a software no adaptativo, los sistemas de tutoría inteligente (STI) producen ganancias de magnitud moderada y, en algunos casos, comparables a la tutoría humana; sin embargo, tales efectos varían según la granularidad de la interacción y la alineación con el currículo. Esta heterogeneidad advierte contra inferencias simplistas: no es “la IA” en abstracto lo que rinde, sino configuraciones específicas que densifican los ciclos de práctica-retroalimentación y sitúan al estudiante en una zona óptima de desafío. Al mismo tiempo, la síntesis cuantitativa disponible, si bien metodológicamente rigurosa, se nutre de estudios con diversidad de dominios, contextos y medidas; por ello, la generalización a todas las áreas curriculares de educación básica debe hacerse con prudencia y bajo marcos explícitos de transferibilidad.

Este patrón conduce a una implicación de diseño central: la “personalización” no equivale a itinerarios opacos o a simples variaciones de dificultad, sino a mecanismos instruccionales que articulan diagnóstico granular, secuenciación con propósito y retroalimentación a nivel de paso. La literatura muestra que los STI de grano fino (step-based o substep-based) convergen en efectos cercanos a la tutoría humana, mientras que los enfoques answer-based —que interactúan solo a nivel de respuesta final— rinden menos al carecer de andamiaje oportuno y específico. De aquí se desprende un principio operativo: la adaptación debe ser explicable didácticamente (qué objetivo persigue cada decisión, con qué evidencia y bajo qué criterio de salida) y trazable a competencias curriculares, so pena de producir “rutas” eficientes en lo computacional pero subóptimas en lo pedagógico. En suma, la potencia de la

IA se realiza cuando el modelado del estudiante, la recomendación y la retroalimentación componen un bucle diagnóstico-prescriptivo que el docente puede leer, interrogar y ajustar en tiempo real.

No obstante, el rendimiento sin justicia es un espejismo. La literatura sobre sesgo algorítmico en educación documenta que, sin salvaguardas explícitas, los sistemas pueden reproducir y amplificar desigualdades por origen étnico, género, estatus socioeconómico o discapacidad. La transición de la “equidad formal” (paridad de métricas agregadas) hacia una equidad sustantiva exige auditorías periódicas, métricas sensibles a subgrupos y rediseños sociotécnicos que incorporen voces docentes y comunitarias. En clave institucional, la analítica del aprendizaje —frecuentemente el motor de la personalización— demanda una gobernanza de datos que haga operativos principios de consentimiento informado, minimización y transparencia sobre usos secundarios, con mecanismos accesibles de explicación y reparación. En educación básica, donde las decisiones automatizadas pueden orientar tempranamente trayectorias, el umbral ético no es solo la conformidad normativa: cada captura y uso de datos debe ostentar una justificación pedagógica clara y proporcional (Piedra-Castro et al., 2024).

La agencia docente emerge como condición de posibilidad para la adopción con sentido pedagógico. Cuando los sistemas proporcionan analíticas *accionables* y explicables —no meramente paneles densos de indicadores—, el profesorado puede reorquestar con mayor precisión (p. ej., reagrupamientos dinámicos, ajustes del andamiaje, intervenciones *just-in-time*), con efectos añadidos sobre el compromiso y la equidad de atención. La investigación basada en co-diseño en aulas K-12 ilustra que la “explicabilidad para la docencia” (por qué se sugiere *esto*, sustentado en *qué* evidencia) y el control humano sobre umbrales y alertas son determinantes de la apropiación, al convertir la IA en infraestructura para la evaluación formativa más que en “caja negra” prescriptiva. La sostenibilidad, por su parte, se juega en tres frentes: desarrollo profesional continuo (lectura crítica de evidencias algorítmicas), alineación

con el currículo y políticas de datos auditables; sin esta tríada, la innovación queda confinada a pilotos con escasa capacidad de escala (Piedra-Castro et al., 2024).

De este análisis derivan líneas concretas para la investigación y la política educativa. Primero, urge ampliar los ensayos controlados aleatorizados y los diseños cuasi-experimentales en educación básica con seguimiento longitudinal, para estimar retención, transferencia y efectos en subpoblaciones, además de costos y razón costo-efectividad frente a alternativas pedagógicas. Segundo, se requieren protocolos de *human-in-the-loop* que especifiquen qué decisiones permanecen bajo deliberación docente y cómo se integran las recomendaciones algorítmicas a la evaluación formativa. Tercero, deben institucionalizarse auditorías de equidad con indicadores sensibles al contexto, junto con marcos de privacidad que armonicen beneficio pedagógico y protección de derechos. Finalmente, la evidencia invita a pensar la IA no como un fin, sino como un medio para expandir la capacidad de diagnóstico y retroalimentación del sistema escolar, manteniendo el juicio profesional del docente como instancia última de validación. En la medida en que las implementaciones honren estos principios —granularidad y trazabilidad pedagógicas, justicia algorítmica y gobernanza de datos, y complementariedad efectiva con la docencia—, la personalización mediada por IA podrá materializar su promesa sin incurrir en atajos que comprometan la integridad educativa (Cajamarca-Correa et al., 2024).

Conclusión

Las evidencias sintetizadas permiten concluir que las estrategias pedagógicas mediadas por IA aportan mejoras consistentes y pedagógicamente significativas en aprendizaje y participación del estudiantado de educación básica, siempre que operen como amplificadores de la evaluación formativa y no como sustitutos de la docencia. La personalización efectiva no se reduce a variar la dificultad: exige granularidad diagnóstica, secuenciación con propósito y

retroalimentación a nivel de paso, de modo que cada decisión algorítmica sitúe al estudiante en su zona óptima de desafío y sustente ciclos reiterados de práctica-feedback.

La eficacia depende tanto del diseño instruccional como de la alineación con el currículo. Los entornos que articulan modelado del estudiante, reglas claras de prescripción y criterios de salida trazables a competencias curriculares muestran ventajas superiores a los que ofrecen adaptaciones superficiales u opacas. Por ello, la explicabilidad didáctica —por qué se recomienda una actividad, con base en qué evidencias y bajo qué umbral— es condición de calidad y de uso responsable en aula.

En términos de implementación, el rol docente es insustituible. La complementariedad docente-IA se materializa cuando las herramientas entregan analíticas accionables, oportunas y comprensibles, que habilitan reorquestar la clase (reagrupamientos, ajustes de andamiaje, intervenciones just-in-time) sin erosionar la agencia profesional. El desarrollo profesional continuo, el soporte técnico y la coordinación curricular constituyen palancas para transitar de pilotos aislados a prácticas institucionalizadas y sostenibles.

Desde una perspectiva de justicia, la personalización mediada por IA solo es legítima si incorpora salvaguardas robustas de equidad y privacidad. La gobernanza de datos debe priorizar minimización, de-identificación, propósitos explícitos y mecanismos de objeción y reparación, mientras que la evaluación de impacto debe monitorear efectos diferenciales por subgrupos para prevenir la amplificación de brechas. La meta no es la “paridad” agregada, sino la equidad sustantiva en resultados y oportunidades.

En consecuencia, las instituciones educativas que aspiren a escalar estas estrategias deberían avanzar mediante despliegues graduales y de bajo riesgo, con ciclos de co-diseño y mejora continua, métricas compartidas de éxito (aprendizaje, participación, equidad, carga docente) y políticas claras sobre datos. Una agenda de investigación prioritaria incluye ensayos con seguimiento longitudinal, análisis de costo-efectividad frente a alternativas pedagógicas,

estudios mixtos que capten mecanismos y condiciones de contexto, y replicaciones en diversos sistemas escolares —incluidos los de habla hispana— para fortalecer la validez externa.

Finalmente, esta revisión se reconoce limitada por la heterogeneidad de diseños y métricas, la posible subrepresentación de contextos no angloparlantes y la evolución acelerada del campo. Ello refuerza la necesidad de revisiones “vivas” y de marcos institucionales que combinen rigor pedagógico, prudencia ética y visión de sistema. Bajo estas condiciones, la IA puede consolidarse como instrumento para expandir capacidades de diagnóstico y retroalimentación, y así materializar una personalización genuina, equitativa y sostenible en educación básica.

Referencias bibliográficas

- Alcivar-Cordova, D. M., Saavedra-Calberto, I. M., Ayala-Chavez, N. E., Pazmiño-Sarriá, M. E., & Ordoñez-Loor, I. I. (2025). Desigualdades educativas y estrategias de inclusión en bachillerato en entornos socioeconómicos diversos. *Revista Científica Ciencia Y Método*, 3(1), 84-98. <https://doi.org/10.55813/gaea/rcym/v3/n1/55>
- Alfredo, R., Echeverría, V., Jin, Y., Yan, L., Swiecki, Z., Gašević, D., & Martínez-Maldonado, R. (2024). Human-centred learning analytics and AI in education: A systematic literature review. *Computers and Education: Artificial Intelligence*, 6, 100215. <https://doi.org/10.1016/j.caeai.2024.100215>
- Baker, R. S., & Hawn, A. (2021). Algorithmic bias in education. *International Journal of Artificial Intelligence in Education*, 31(1), 1–41. <https://doi.org/10.1007/s40593-021-00285-9>
- Bang, H. J., Li, L., & Flynn, K. (2023). Efficacy of an adaptive game-based math learning app to support personalized learning and improve early elementary school students' learning. *Early Childhood Education Journal*, 51, 717–732. <https://doi.org/10.1007/s10643-022-01332-3>
- Bazurto-Mendoza, A. B., Vera-Peña, M. A., Maliza-Muñoz, W. F., & Gómez-Rodríguez, V. G. (2025). Estrategia pedagógica del uso de los recursos digitales para la educación remota. *Revista Científica Zambos*, 4(2), 1-20. <https://doi.org/10.69484/rcz/v4/n2/105>
- Caicedo-Basurto, R. L., Camacho-Medina, B. M., Quinga-Villa, C. A., Fonseca-Lombeida, A. F., & López-Freire, S. A. (2024). Análisis y beneficios de la educación en la era de la inteligencia artificial. *Journal of Economic and Social Science Research*, 4(4), 291–302. <https://doi.org/10.55813/gaea/jessr/v4/n4/148>
- Cajamarca-Correa, M. A., Cangas-Cadena, A. L., Sánchez-Simbaña, S. E., & Pérez-Guillermo, A. G. (2024). Nuevas tendencias en el uso de recursos y herramientas de la Tecnología Educativa para la Educación Universitaria. *Journal of Economic and Social Science Research*, 4(3), 127–150. <https://doi.org/10.55813/gaea/jessr/v4/n3/124>

- Fletcher, J. D., & Kulik, J. A. (2016). Effectiveness of intelligent tutoring systems: A meta-analytic review. *Review of Educational Research*, 86(1), 42–78. <https://doi.org/10.3102/0034654315581420>
- Khor, E. T., & Mutthulakshmi, K. (2024). A systematic review of the role of learning analytics in supporting personalized learning. *Education Sciences*, 14(1), 51. <https://doi.org/10.3390/educsci14010051>
- 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>
- Moreira-Alcivar, E. F. (2025). Aprendizaje basado en retos (ABR) para el fomento del pensamiento creativo y divergente en adolescentes: diseño, implementación y evaluación en contextos escolares del nivel secundario. *Revista Científica Zambos*, 4(2), 171–184. <https://doi.org/10.69484/rcz/v4/n2/119>
- Piedra-Castro, W. I., Burbano-Buñay, E. S., Tamayo-Verdezoto, J. J., & Moreira-Alcívar, E. F. (2024). Inteligencia artificial y su incidencia en la estrategia metodológica de aprendizaje basado en investigación. *Journal of Economic and Social Science Research*, 4(2), 178–196. <https://doi.org/10.55813/gaea/jessr/v4/n2/106>
- Piedra-Castro, W. I., Cajamarca-Correa, M. A., Burbano-Buñay, E. S., & Moreira-Alcívar, E. F. (2024). Integración de la inteligencia artificial en la enseñanza de las Ciencias Sociales en la educación superior. *Journal of Economic and Social Science Research*, 4(3), 105–126. <https://doi.org/10.55813/gaea/jessr/v4/n3/123>
- Rodriguez-Ayala, A. E., Ayala-Tigmasi, R. A., Anchundia-Aristega, Y. X., Días-Pilatasig, M. J., & Arias-Arias, J. L. (2024). Análisis del modelo ERCA y su aporte en las planificaciones curriculares. *Journal of Economic and Social Science Research*, 4(4), 278–290. <https://doi.org/10.55813/gaea/jessr/v4/n4/147>
- Saavedra-Calberto, I. M., Esmeraldas-Espinoza, A. A., Ayala-Chavez, N. E., Reina-Bravo, E. G., & Ordoñez-Loor, I. I. (2025). Factores determinantes del rendimiento académico en estudiantes de bachillerato en instituciones públicas. *Revista Científica Ciencia Y Método*, 3(1), 72–83. <https://doi.org/10.55813/gaea/rcym/v3/n1/54>
- Salazar-Alcivar, A. N., Alcivar-Córdova, D. M., Flores-Verdesoto, G. E., Montaña-Villa, J. J., & Salazar-Alcivar, L. E. (2024). Educación ambiental como herramienta para fomentar la conciencia ecológica en estudiantes de secundaria. *Revista Científica Ciencia Y Método*, 2(2), 40–52. <https://doi.org/10.55813/gaea/rcym/v2/n2/42>
- Sornoza-Delgado, Y. M. (2025). Estrategias para aplicar la pedagogía culturalmente receptiva en el aula. *Journal of Economic and Social Science Research*, 5(1), 201–213. <https://doi.org/10.55813/gaea/jessr/v5/n1/170>
- Tan, L. Y., Hu, S., Yeo, D. J., & Cheong, K. H. (2025). Artificial intelligence-enabled adaptive learning platforms: A review. *Computers and Education: Artificial Intelligence*, 9, 100429. <https://doi.org/10.1016/j.caeai.2025.100429>
- Tan, X., Cheng, G., & Ling, M. H. (2025). Artificial intelligence in teaching and teacher professional development: A systematic review. *Computers and Education: Artificial Intelligence*, 8, 100355. <https://doi.org/10.1016/j.caeai.2024.100355>
- VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 46(4), 197–221. <https://doi.org/10.1080/00461520.2011.611369>

Wang, S., Wang, F., Zhu, Z., Wang, J., & Tran, T. (2024). Artificial intelligence in education: A systematic literature review. *Expert Systems with Applications*, 252, 124167. <https://doi.org/10.1016/j.eswa.2024.124167>