

Inteligencia artificial, motivación académica y aprendizaje personalizado en contextos educativos rurales: revisión sistemática 2020–2025

Artificial intelligence, academic motivation, and personalized learning in rural educational contexts: A systematic review 2020–2025

Carmen Alicia Cantillo Cardoza¹  Ana Cristina Herrera Ríos² 

¹Carmen Alicia Cantillo Cardoza. carmen.cantilloc2025@uted.us. University of Technology and Education

²Ana Cristina Herrera Ríos. ana.herrera@uted.us. University of Technology and Education

DOI:

<https://doi.org/10.67461/1sq5kh54>

Correo del autor:

carmen.cantilloc2025@uted.us

ana.herrera@uted.us

Fecha de recepción:

5/7/2025

Fecha de aceptación:

10/9/2025

Fecha de publicación:

01/01/2026

Resumen

El objetivo fue analizar la evidencia publicada entre 2020 y 2025 sobre la relación entre inteligencia artificial educativa, motivación académica, aprendizaje personalizado y educación rural. Se realizó una revisión sistemática descriptivo-analítica conforme a PRISMA 2020 en Scopus, ERIC, Redalyc y SciELO. Los registros se depuraron mediante coincidencia de DOI, título y autoría en una hoja de cálculo, seguida de verificación manual. De 1.641 registros identificados, 1.214 pasaron al cribado, 136 se evaluaron a texto completo y 30 integraron la síntesis cualitativa. Seis estudios abordaron de manera directa entornos rurales y los demás aportaron evidencia transferible sobre personalización, retroalimentación, motivación, formación docente y ética. Los hallazgos indican que la IA puede favorecer la participación, la autoeficacia y el aprendizaje cuando ofrece apoyo adaptativo y retroalimentación comprensible; sin embargo, sus efectos disminuyen cuando existen conectividad inestable, dispositivos insuficientes, baja alfabetización digital o escasa mediación pedagógica. La evidencia fue más consistente para la mediación docente y las condiciones de implementación que para efectos sostenidos sobre la motivación, debido al predominio de diseños descriptivos y estudios de corta duración. Se concluye que la IA educativa debe entenderse como apoyo sociotécnico y no como sustituto del docente. En escuelas rurales su implementación requiere herramientas de bajo consumo de datos, formación situada, protocolos de privacidad y selección curricular contextualizada.

Palabras clave: inteligencia artificial educativa; motivación académica; aprendizaje personalizado; educación rural; formación docente; PRISMA.

Citar Como: Inteligencia artificial, motivación académica y aprendizaje personalizado en contextos educativos rurales: revisión sistemática 2020–2025. (s. f.). Encuentros Educativos, 2(1). <https://doi.org/10.67461/1sq5kh54>



This work is licensed under Creative Commons Attribution-NonCommercial 4.0 International License

Abstract

This study analyzed evidence published between 2020 and 2025 on the relationship among educational artificial intelligence, academic motivation, personalized learning, and rural education. A descriptive-analytical systematic review was conducted following PRISMA 2020 in Scopus, ERIC, Redalyc, and SciELO. Records were deduplicated in a spreadsheet through DOI, title, and authorship matching, followed by manual verification. Of 1,641 identified records, 1,214 were screened, 136 were assessed in full text, and 30 were included in the qualitative synthesis. Six studies directly addressed rural settings, while the remaining studies provided transferable evidence on personalization, feedback, motivation, teacher development, and ethics. Findings indicate that AI can support participation, self-efficacy, and learning when it provides adaptive assistance and understandable feedback. Its effects are weakened by unstable connectivity, insufficient devices, limited digital literacy, and inadequate pedagogical mediation. Evidence was more consistent for teacher mediation and implementation conditions than for sustained motivational effects because descriptive and short-term studies predominated. Educational AI should therefore be understood as sociotechnical support rather than a replacement for teachers. In rural schools, implementation requires low-bandwidth tools, context-based professional development, privacy protocols, and curriculum-aligned selection.

Keywords: educational artificial intelligence; academic motivation; personalized learning; rural education; teacher professional development; PRISMA.

Introducción

La inteligencia artificial educativa se refiere a sistemas computacionales capaces de inferir patrones, generar contenido, predecir desempeños, recomendar recursos o adaptar actividades a partir de datos y reglas algorítmicas. Esta definición la distingue de la tecnología educativa general, las tecnologías de la información y la comunicación (TIC), las plataformas digitales o los recursos virtuales que no incorporan funciones de inferencia, generación o adaptación automatizada (Holmes et al., 2019; Mujica-Sequera, 2024). Por ello, no toda aplicación digital utilizada en el aula constituye IA educativa.

El interés por estas herramientas se relaciona con su potencial para ofrecer retroalimentación inmediata, ajustar la dificultad, recomendar trayectorias y apoyar el seguimiento del progreso. Tales funciones pueden incidir en la motivación académica cuando fortalecen la percepción de competencia, la autonomía, el interés y la participación. No obstante, los sistemas adaptativos no producen estos efectos de manera automática: requieren objetivos curriculares claros, actividades comprensibles, retroalimentación pertinente y mediación humana que evite respuestas mecánicas o descontextualizadas (Aparicio-Gómez & Aparicio-Gómez, 2024; Carbonell Bernal & Hernández Prados, 2024).

El problema adquiere especial relevancia en la educación rural. Las escuelas rurales suelen atender grupos heterogéneos o multigrado, disponer de menos apoyo especializado y enfrentar dispersión

geográfica, conectividad irregular, dispositivos compartidos y oportunidades limitadas de formación continua. En esas condiciones, la IA podría ayudar a diversificar materiales, brindar práctica guiada y organizar el seguimiento; sin embargo, también podría profundizar desigualdades si su funcionamiento depende de conexión permanente, licencias costosas, interfaces poco inclusivas o uso intensivo de datos personales (Guanga Inca et al., 2024; Montiel-Ruiz & López Ruiz, 2023; Uribe-Zapata et al., 2023; UNESCO, 2024).

La literatura reciente presenta un vacío doble. Por una parte, numerosos estudios se concentran en contextos urbanos, instituciones con mejor infraestructura o experiencias de corta duración; por otra, son escasas las investigaciones que miden de forma sostenida la motivación académica y el aprendizaje personalizado en escuelas rurales. Además, los estudios directos sobre ruralidad suelen priorizar percepciones docentes y barreras de implementación, mientras que los estudios experimentales sobre motivación se realizan en contextos con mayor disponibilidad tecnológica. Esta separación dificulta establecer en qué condiciones los beneficios observados pueden transferirse a comunidades rurales (Castro et al., 2025; Jeon, 2025; Kim & Wargo, 2025; Mokoena & Seeletse, 2025).

La pregunta de revisión fue: ¿cómo se relacionan la inteligencia artificial educativa, la motivación académica y el aprendizaje personalizado en contextos educativos rurales durante 2020–2025? El objetivo consistió en analizar la producción académica reciente, identificar acuerdos, contradicciones y vacíos metodológicos, y derivar orientaciones prácticas para docentes y líderes escolares rurales. Holmes et al. (2019) se conservó como referente conceptual anterior al periodo y no se

contabilizó dentro del corpus sistemático.

Materiales y métodos

Diseño del estudio

Se desarrolló una revisión sistemática de literatura con alcance descriptivo-analítico y enfoque documental. El procedimiento siguió las etapas de identificación, cribado, elegibilidad e inclusión propuestas por PRISMA 2020 (Page et al., 2021). No se realizó metaanálisis porque los estudios presentaron heterogeneidad en diseños, participantes, herramientas de IA, variables motivacionales y medidas de aprendizaje. Holmes et al. (2019), Page et al. (2021) y UNESCO (2024) se utilizaron como fuentes externas de carácter conceptual, metodológico y normativo, respectivamente; no se contabilizaron dentro de los 30 estudios del corpus sistemático ni se incluyeron en las tablas del Anexo A.

Fuentes de información y estrategia de búsqueda

La búsqueda se efectuó en Scopus, ERIC, Redalyc y SciELO. Se combinaron términos en español e

inglés sobre inteligencia artificial educativa, aprendizaje adaptativo, sistemas de tutoría inteligente, analítica de aprendizaje, motivación, participación, aprendizaje personalizado, escuela rural y ruralidad. Las búsquedas priorizaron título, resumen y palabras clave cuando la plataforma lo permitió. Las ecuaciones utilizadas se presentan en la Tabla 1.

Tabla 1. Ecuaciones de búsqueda aplicadas por base de datos

Base de datos	Ecuación de búsqueda	Filtros
Scopus	TITLE-ABS-KEY(("artificial intelligence" OR "AI" OR "adaptive learning" OR "intelligent tutoring system*" OR "learning analytics" OR "generative AI") AND ("academic motivation" OR "student motivation" OR engagement OR "personalized learning" OR "school learning") AND ("rural education" OR "rural school*" OR rural)) AND NOT ("higher education" OR university OR undergraduate)	2020–2025; español, inglés o portugués; artículos y revisiones.
ERIC	("artificial intelligence" OR "adaptive learning" OR "intelligent tutoring systems" OR "learning analytics" OR "generative AI") AND (motivation OR engagement OR "personalized learning" OR "school learning") AND ("rural education" OR "rural schools") NOT "higher education"	Peer reviewed; 2020–2025; primaria, secundaria o K-12.
Redalyc	("inteligencia artificial" OR "aprendizaje adaptativo" OR "tutoría inteligente" OR "analítica de aprendizaje") AND ("motivación académica" OR "participación estudiantil" OR "aprendizaje personalizado") AND ("educación rural" OR "escuela rural" OR ruralidad) NOT "educación superior"	2020–2025; español o portugués; texto completo.
SciELO	("inteligencia artificial" OR "aprendizaje adaptativo" OR "tutoría inteligente" OR "analítica de aprendizaje") AND (motivación OR participación OR "aprendizaje personalizado") AND ("educación rural" OR "escuela rural" OR ruralidad) NOT universidad	2020–2025; español, inglés o portugués; texto completo.

Operadores booleanos empleados

El operador AND exigió la presencia simultánea de los ejes IA, motivación o aprendizaje y ruralidad; OR incorporó términos equivalentes; y NOT excluyó estudios centrados exclusivamente en educación superior. El término TIC no se utilizó como sinónimo

de IA, sino únicamente para recuperar estudios rurales que explicaran condiciones de infraestructura y transferencia pedagógica.

Criterios de inclusión y exclusión

Los criterios aplicados se resumen en la Tabla 2. Se incluyeron estudios con evidencia rural directa o con

resultados claramente transferibles a escuelas personalizado.
rurales, siempre que abordaran IA educativa,
motivación, participación o aprendizaje

Tabla 2. Criterios de inclusión y exclusión

Criterio	Inclusión	Exclusión
Periodo	Publicaciones entre 2020 y 2025. Holmes et al. (2019) se mantuvo solo como referencia conceptual externa.	Publicaciones fuera del periodo, salvo la referencia conceptual indicada.
Tipo de documento	Artículos empíricos, revisiones académicas y estudios con información metodológica suficiente.	Opinión, prensa, divulgación o documentos sin sustento metodológico.
Nivel educativo	Educación primaria, básica, secundaria, media o K-12.	Educación superior exclusiva.
Tecnología	IA educativa, aprendizaje adaptativo, tutoría inteligente, analítica, aprendizaje automático o IA generativa aplicada a educación.	Tecnología educativa general sin función de inferencia, generación, predicción o adaptación automatizada.
Variables	Motivación, participación, autoeficacia, rendimiento, retroalimentación o personalización.	Sin relación con experiencia, motivación o aprendizaje escolar.
Contexto	Ruralidad directa o implicaciones explícitas y justificadas para escuelas rurales.	Sin referencia territorial ni posibilidad de transferencia razonada.
Acceso e idioma	Texto completo en español, inglés o portugués.	Sin acceso suficiente o datos bibliográficos incompletos.

Depuración y proceso de selección PRISMA

Los resultados se exportaron a una hoja de cálculo. La eliminación de duplicados se realizó en dos etapas: primero se identificaron coincidencias por DOI; después se compararon títulos normalizados, autoría y año. Los registros con variaciones ortográficas o metadatos incompletos se revisaron manualmente antes de excluirlos. Esta depuración permitió conservar una trazabilidad de las decisiones y evitar la eliminación automática de estudios distintos con títulos similares.

Se identificaron 1.641 registros. Durante la depuración inicial se eliminaron 427 registros duplicados o claramente no pertinentes, por lo que 1.214 pasaron al cribado por título y resumen. En esta fase se excluyeron 1.078. Posteriormente, 136 textos completos fueron evaluados y 106 se excluyeron por falta de ruralidad directa o pertinencia transferible, ausencia de IA educativa, educación superior exclusiva, falta de variables motivacionales o de aprendizaje, acceso incompleto o información metodológica insuficiente. El flujo se ilustra en la Figura 1.




Figura 1. Diagrama PRISMA del proceso de identificación, cribado, elegibilidad e inclusión.

Extracción y análisis de la información

Los 30 estudios se registraron en una matriz con autoría, año, país, objetivo, metodología, muestra o contexto, hallazgos y aporte al tema. La síntesis combinó codificación deductiva —personalización, retroalimentación, motivación, mediación docente, ruralidad y ética— con categorías emergentes. La matriz completa se presenta en el Anexo A y sus patrones se analizan en la sección de resultados.

Para interpretar la solidez de los hallazgos sin homogeneizar diseños diferentes, se realizó una valoración cualitativa de la fortaleza inferencial a partir de la información registrada en la matriz: tipo de diseño, claridad del contexto o la muestra y correspondencia entre objetivo, método y resultados. Los estudios experimentales o cuasiexperimentales se consideraron más informativos para estimar cambios de corto plazo; las encuestas, entrevistas y estudios de caso se utilizaron principalmente para comprender condiciones de implementación; y las revisiones aportaron convergencia conceptual. Esta valoración orientó la síntesis de consistencia presentada en la Tabla 3 y no constituyó una escala formal de riesgo de sesgo.

Resultados

El corpus quedó conformado por 30 estudios: cinco revisiones o trabajos analíticos, seis investigaciones con abordaje rural directo y diecinueve estudios empíricos transferibles a educación rural. Las Tablas A1 y A2 incluyen exclusivamente esos 30 documentos; Holmes et al. (2019), Page et al. (2021) y UNESCO (2024) se utilizaron como apoyos conceptual, metodológico y normativo y no se incorporaron al recuento. En los estudios rurales directos predominaron encuestas, entrevistas y estudios de caso, por lo que su aporte fue más sólido para identificar barreras, oportunidades y condiciones de adopción que para establecer efectos causales sobre la motivación o el aprendizaje. Estos estudios se localizaron en España, Colombia, Chile, Corea del Sur, Sudáfrica y Estados Unidos y coincidieron en que la infraestructura y la formación explican buena parte de la distancia entre el potencial técnico y el uso pedagógico real (Castro et al., 2025; Jeon, 2025; Kim & Wargo, 2025; Mokoena & Seeletse, 2025; Montiel-Ruiz & López Ruiz, 2023; Uribe-Zapata et al., 2023).

La personalización apareció en 18 estudios como adaptación de dificultad, rutas, contenidos, tareas o retroalimentación. La consistencia de la evidencia fue moderada-alta para resultados de corto plazo: las revisiones de Aparicio-Gómez y Aparicio-Gómez (2024), Bolaño-García y Duarte-Acosta (2024) y Carbonell Bernal y Hernández

Prados (2024) convergieron en que la adaptación puede mejorar la experiencia de aprendizaje cuando existe diseño pedagógico, mientras que intervenciones en escritura, matemática e idiomas reportaron mejoras en interés, autoeficacia, participación o desempeño (Kızıldaş, 2025; Liu et al., 2025; Taşdelen & Bodemer, 2025; Yuan, 2024; Zheng & Tse, 2023). Bagabas (2025) añadió evidencia perceptual sobre beneficios de la personalización para estudiantes con dificultades de aprendizaje. No obstante, predominan estudios de duración limitada y no se dispone de seguimiento suficiente para afirmar que los efectos se sostengan en el tiempo; además, los beneficios fueron menos consistentes cuando el sistema carecía de andamiaje, producía errores o exigía una conectividad superior a la disponible.

La motivación no se presentó como una consecuencia inherente de la IA. La evidencia fue moderada y dependiente del contexto, pues combinó estudios de caso, autoinformes y mediciones inmediatas. En la comparación de Jeon (2025), la gamificación favoreció el interés en ambos contextos, pero la escuela rural tuvo menor apoyo para el uso independiente. De forma semejante, Huang (2021), Lee et al. (2021) y Zheng y Tse (2023) mostraron que la novedad, la interacción y la retroalimentación pueden elevar la participación, aunque el efecto depende de la calidad de la tarea y la presencia del docente. Walan (2025) incorporó la perspectiva estudiantil y mostró una valoración ambivalente: los estudiantes reconocieron apoyos prácticos, pero también expresaron preocupaciones por la privacidad y los efectos sociales de la IA. En conjunto, la evidencia respalda incrementos motivacionales situados, no una mejora automática o generalizable.

La mediación docente fue el patrón más transversal y presentó la mayor convergencia temática, con presencia en 21 estudios. Las investigaciones sobre preparación, desarrollo profesional y adopción mostraron que las actitudes favorables no garantizan integración curricular. La capacidad para verificar resultados, formular instrucciones, interpretar datos y adaptar actividades se relacionó con el conocimiento pedagógico-tecnológico, el apoyo institucional y la experiencia situada (Batubara et al., 2025; Dai, 2023; Huang & Yu, 2024; Li & Manzari, 2025; Li & Zhang, 2024; Sperling et al., 2022). Chakraborty et al. (2024) evidenciaron que la alfabetización en IA requiere progresiones y andamiajes didácticos, mientras que Getenet (2024) mostró que la IA puede ampliar estrategias de resolución, pero también generar errores que exigen revisión profesional. Aunque buena parte de esta evidencia es descriptiva u observacional, la coincidencia entre países y diseños fortalece su utilidad para explicar condiciones de implementación.

En ética y equidad se identificaron preocupaciones sobre privacidad, sesgos, transparencia, alucinaciones, dependencia y propiedad de los datos. La consistencia

conceptual fue alta, aunque la evaluación empírica de estos riesgos fue limitada. Las inquietudes se intensifican en comunidades pequeñas, donde la anonimización puede ser más difícil y las posibilidades de cambiar de proveedor o plataforma son reducidas. Jiang y Li (2023) mostraron que los diseños tecnológicos sofisticados pueden favorecer la participación, pero dependen de infraestructura difícil de transferir a contextos con recursos escasos. Uğraş et al. (2024) destacaron la necesidad de formación para docentes y familias ante alucinaciones y privacidad, y Walan (2025)

confirmó que estas preocupaciones también aparecen en la voz de los estudiantes. Los estudios rurales recomendaron políticas claras, conectividad sostenible, herramientas que funcionen con bajo ancho de banda y formación que incluya competencias técnicas y decisiones éticas (Castro et al., 2025; Kim & Wargo, 2025; Mokoena & Seeletse, 2025; UNESCO, 2024).

La distribución analítica de hallazgos se presenta en la Tabla 3.

Tabla 3. Síntesis de consistencia, fortaleza e implicaciones de los hallazgos del corpus

Dimensión	Consistencia y fortaleza de la evidencia	Hallazgo integrado	Implicación rural
Personalización (n = 18)	Moderada-alta. Convergencia entre revisiones e intervenciones de corto plazo; sin seguimiento longitudinal suficiente.	La adaptación de tareas, rutas y retroalimentación se asocia con interés, autoeficacia y desempeño cuando el contenido es pertinente y verificable.	Priorizar funciones simples, revisables y de bajo consumo de datos para grupos multigrado o heterogéneos.
Motivación y participación (n = 14)	Moderada y condicionada. Predominan autoinformes, estudios de caso y mediciones inmediatas.	La novedad, la gamificación y la interacción pueden favorecer la participación, pero no sostienen el compromiso sin apoyo pedagógico.	Combinar IA con metas claras, cooperación, acompañamiento y actividades contextualizadas.
Mediación y formación docente (n = 21)	Alta convergencia transversal. Evidencia sobre todo descriptiva u observacional, sólida para explicar implementación.	El docente verifica, interpreta, contextualiza y decide; la preparación técnica aislada es insuficiente.	Desarrollar formación situada, comunidades de práctica y guías para seleccionar y revisar herramientas.
Infraestructura y equidad (n = 11)	Alta en los contextos rurales estudiados. Predominan diseños cualitativos y estudios de caso.	La conectividad, los equipos y el soporte condicionan la implementación y pueden ampliar la brecha.	Evaluar costo total, funcionamiento asincrónico, disponibilidad de dispositivos y soporte local antes de adoptar.
Ética y datos (n = 16)	Alta consistencia conceptual; evidencia empírica todavía limitada sobre incidencia y mitigación de riesgos.	Persisten riesgos de privacidad, sesgo, opacidad, dependencia y errores generativos.	Aplicar consentimiento, minimización de datos, revisión humana y protocolos específicos para menores de edad.
Evidencia rural directa (n = 6)	Baja-moderada para efectos causales; alta relevancia contextual para barreras, liderazgo y adopción.	Predominan estudios de percepciones y adopción; faltan diseños longitudinales sobre motivación y aprendizaje.	Realizar pilotos evaluables y comparaciones rural-urbano con indicadores sostenidos.

Nota. Las categorías no son excluyentes; un mismo estudio puede contribuir a varias dimensiones. La fortaleza se interpretó cualitativamente según el diseño y la información metodológica disponible, sin aplicar una escala formal de riesgo de sesgo.

Discusión crítica

Los resultados confirman un acuerdo amplio: la IA puede apoyar el aprendizaje cuando ofrece

retroalimentación útil, práctica diferenciada y oportunidades de participación. Esta convergencia aparece en revisiones sobre IA educativa, sistemas adaptativos y tutoría inteligente (Aparicio-Gómez & Aparicio-Gómez, 2024; Bolaño-García & Duarte-Acosta, 2024; Carbonell Bernal & Hernández Prados, 2024) y en intervenciones de escritura, matemática e idiomas (Kızıltaş, 2025; Liu et al., 2025; Taşdelen & Bodemer, 2025; Yuan, 2024). Bagabas (2025) amplía esta lectura hacia la educación inclusiva, aunque desde percepciones

docentes. La evidencia más fuerte se concentra en efectos de corto plazo y contextos con acompañamiento; por tanto, el acuerdo se refiere al potencial bajo determinadas condiciones, no a un efecto universal ni sostenido.

La principal contradicción se observa entre estudios experimentales con infraestructura controlada y estudios rurales centrados en implementación. Mientras los primeros reportan incrementos de motivación o desempeño, los segundos muestran que la falta de conectividad, dispositivos, soporte y tiempo de formación reduce la exposición efectiva a la herramienta. Jeon (2025) evidenció que una misma aplicación produjo experiencias distintas según el apoyo disponible; Castro et al. (2025), Kim y Wargo (2025) y Mokoena y Seeletse (2025) coincidieron en que la preparación docente y la infraestructura son condiciones de equidad, no factores secundarios. Asimismo, Jiang y Li (2023) ilustran que propuestas con realidad virtual, IA e Internet de las cosas pueden estimular la indagación, pero su complejidad técnica limita la transferencia a escuelas con recursos mínimos.

Otra tensión se relaciona con la automatización. Los sistemas pueden ahorrar tiempo, ampliar estrategias y generar materiales, pero también desplazan hacia el docente nuevas tareas de verificación, curaduría, protección de datos y explicación de errores. Getenet (2024) mostró que ChatGPT puede diversificar procedimientos de resolución de problemas, aunque sus respuestas requieren comprobación y adaptación por edad. Sperling et al. (2022) señalaron que la automatización redistribuye responsabilidades en lugar de eliminarlas, y Dai (2023), Huang y Yu (2024) y Li y Zhang (2024) relacionaron la integración con conocimientos pedagógicos y condiciones institucionales. A ello se suman las preocupaciones por alucinaciones, privacidad y alfabetización ética planteadas por Uğraş et al. (2024) y por los propios estudiantes en Walan (2025). Por tanto, la IA no sustituye la relación educativa; aumenta la necesidad de juicio profesional y gobernanza institucional.

El vacío de conocimiento permanece en la medición sostenida de motivación y aprendizaje en ruralidad. Solo seis estudios del corpus abordaron contextos rurales de forma directa y la mayoría utilizó encuestas, entrevistas o estudios de caso. Son escasos los diseños longitudinales, las comparaciones rural-urbano, las mediciones validadas de motivación y las evaluaciones de herramientas que funcionen con conectividad intermitente. También faltan estudios sobre lenguas locales, aulas multigrado, costos de mantenimiento, accesibilidad para estudiantes con necesidades diversas y efectos de la protección de datos en comunidades pequeñas. En consecuencia, la literatura ofrece una base consistente para orientar implementación y formación, pero todavía limitada para estimar magnitudes de efecto o relaciones causales duraderas.

Implicaciones para docentes y líderes rurales

La evidencia permite formular recomendaciones prácticas. Primero, la selección de herramientas debe comenzar por el problema pedagógico y no por la novedad tecnológica: conviene priorizar soluciones que permitan descargar materiales, trabajar con conexión intermitente, controlar los datos y revisar las respuestas. Segundo, la formación docente debe incluir diseño de actividades, formulación de instrucciones, verificación de errores, lectura de analíticas y estrategias para explicar al estudiante cuándo y por qué una respuesta de IA puede ser incorrecta.

Tercero, la implementación debe iniciarse con pilotos acotados, metas observables y alternativas no digitales para evitar que la falta de conectividad excluya a parte del grupo. Cuarto, las instituciones deben definir reglas sobre consentimiento, datos de menores, cuentas personales, conservación de información y uso de contenido generado. Quinto, la evaluación debe considerar no solo el rendimiento, sino también participación, autonomía, carga docente, accesibilidad, costos y pertinencia cultural.

En la Tabla 4 se sintetizan criterios operativos para seleccionar e implementar herramientas de IA en escuelas rurales.

Tabla 4. Recomendaciones operativas para la implementación rural

Área	Acción recomendada	Indicador de verificación
Formación docente	Formación situada en diseño de actividades, verificación, ética y lectura de datos.	El docente puede explicar el objetivo, revisar la salida y proponer una alternativa sin IA.
Conectividad	Elegir herramientas de bajo ancho de banda, con descarga o trabajo asincrónico.	La actividad puede completarse aun con conexión inestable.
Dispositivos	Planificar uso compartido y accesibilidad; evitar exigir cuentas personales.	Todos los estudiantes tienen una ruta de participación equivalente.
Selección de herr	Revisar edad mínima, idioma, privacidad, costo, soporte, ca	Existe una ficha institucional de evaluación y resp

amiantas	lidad y alineación curricular.	onsable de seguimiento.
Datos y ética	Minimizar datos, obtener consentimiento y prohibir información sensible.	Se documenta qué datos se recopilan, dónde se almacenan y quién accede.
Evaluación	Medir aprendizaje, motivación, participación, carga docente y equidad.	El piloto tiene línea base, indicadores y decisión de continuidad o ajuste.

Limitaciones del estudio

La revisión se limitó a cuatro bases de datos, a textos en español, inglés o portugués y al periodo 2020–2025. Esta delimitación puede haber excluido literatura regional no indexada, informes técnicos, tesis y experiencias comunitarias. La heterogeneidad de diseños, niveles educativos, herramientas y medidas impidió estimar efectos agregados. Además, solo seis estudios abordaron ruralidad de forma directa, por lo que parte de la interpretación se basó en transferencia razonada desde otros contextos. La fortaleza de la evidencia se valoró cualitativamente a partir del diseño y la información metodológica registrada, pero no se aplicó una herramienta formal y común de riesgo de sesgo debido a la diversidad del corpus; por ello, la síntesis permite comparar consistencia y capacidad inferencial general, no clasificar de manera definitiva la calidad de cada estudio. Los resultados deben leerse como patrones de evidencia y no como prueba causal generalizable. La rápida evolución de la IA también puede reducir la vigencia de descripciones específicas de herramientas.

Conclusiones

La inteligencia artificial educativa puede apoyar la motivación académica y el aprendizaje personalizado cuando proporciona retroalimentación comprensible, práctica diferenciada y oportunidades de participación vinculadas con objetivos curriculares. Los resultados más favorables se observan en experiencias con acompañamiento docente, tareas bien diseñadas y posibilidades de revisión humana.

En ruralidad, la conectividad, los dispositivos, la formación, el soporte y la protección de datos determinan si el potencial se convierte en una oportunidad o en una nueva brecha. Por ello, la implementación debe priorizar herramientas accesibles, de bajo consumo de datos, transparentes y pertinentes para la realidad sociocultural de cada comunidad.

La mediación docente sigue siendo decisiva. La IA redistribuye tareas hacia la curaduría, la verificación, la interpretación de datos y el acompañamiento ético; no reemplaza el conocimiento pedagógico ni el vínculo humano. La formación debe integrar competencias técnicas,

didácticas y éticas, con práctica situada y apoyo institucional continuo.

El principal vacío de investigación es la escasez de estudios longitudinales y comparativos en escuelas rurales que midan motivación, participación y aprendizaje con instrumentos validados. Las investigaciones futuras deben evaluar soluciones para conectividad intermitente, aulas multigrado, lenguas locales, costos de sostenibilidad y gobernanza de datos de menores.

Agradecimientos

Las autoras agradecen a la Institución Educativa San Francisco de Asís, ubicada en San Bernardo del Viento, Córdoba, Colombia, por su apoyo académico e institucional. También reconocen los aportes de docentes y directivos que compartieron reflexiones sobre educación rural y tecnologías emergentes.

Fuentes de financiamiento

Esta investigación no recibió financiamiento externo de instituciones públicas, privadas o sin ánimo de lucro. El desarrollo se realizó con recursos propios de las autoras y apoyo académico institucional no remunerado.

Declaración de conflicto de interés

Las autoras declaran no tener conflicto de interés respecto al contenido, los resultados o la interpretación del presente artículo.

Declaración sobre el uso de inteligencia artificial

Las autoras declaran que ChatGPT, desarrollado por OpenAI, se utilizó únicamente como apoyo para la revisión de estilo, organización textual, claridad y corrección lingüística del manuscrito. Las autoras verificaron y editaron todas las salidas. La herramienta no sustituyó la búsqueda bibliográfica, la aplicación de criterios de selección, el análisis del corpus ni la interpretación académica, cuya responsabilidad corresponde exclusivamente a las autoras.

Declaración de contribución de autoras

Carmen Alicia Cantillo Cardoza participó en la concepción del estudio, diseño metodológico, revisión de literatura, análisis de información, interpretación de resultados y redacción del manuscrito. Ana Cristina Herrera Ríos participó en la orientación académica, revisión crítica del contenido, fortalecimiento teórico-metodológico y revisión de la versión final.

Referencias Bibliográficas

Nota de composición del corpus. Las 30 referencias incluidas en las Tablas A1 y A2 conforman el corpus sistemático. Holmes et al. (2019), Page et al. (2021) y UNESCO (2024) son fuentes externas empleadas con fines conceptual, metodológico y normativo, respectivamente.

Aparicio-Gómez, O.-Y., & Aparicio-Gómez, W.-O. (2024). Innovación educativa con sistemas de aprendizaje adaptativo impulsados por inteligencia artificial. *Revista Internacional de Pedagogía e Innovación Educativa*, 4(2), 343–363. <https://doi.org/10.51660/ripie42222>

Bagabas, H. A. (2025). Primary schools teachers' perspectives on AI integration in personalized learning for students with learning disabilities in primary grades. *International Journal of Educational Sciences*, 49(3), 128–134. <https://doi.org/10.31901/24566322.2025/49.03.1399>

Batubara, H. H., Syukur, F., Junaedi, M., Purwanti, K. L., & Shanie, A. (2025). Teachers' perceptions and readiness for mobile artificial intelligence integration in elementary education. *International Journal of Interactive Mobile Technologies*, 19(16), 148–162. <https://doi.org/10.3991/ijim.v19i16.55711>

Bolaño-García, M., & Duarte-Acosta, N. (2024). Una revisión sistemática del uso de la inteligencia artificial en la educación. *Revista Colombiana de Cirugía*, 39(1), 51–63. <https://doi.org/10.30944/20117582.2365>

Carbonell Bernal, N., & Hernández Prados, M. Á. (2024). Impacto de los sistemas de tutoría inteligente. Una revisión sistemática. *EduTec. Revista Electrónica de Tecnología Educativa*, (89), 121–143. <https://doi.org/10.21556/edutec.2024.89.3025>

Castro, A., Díaz, B., Aguilera, C., Prat, M., & Chávez-Herting, D. (2025). Identifying rural elementary teachers' perception challenges and opportunities in integrating artificial intelligence in teaching practices. *Sustainability*, 17(6), Article 2748. <https://doi.org/10.3390/su17062748>

Chakraborty, S., Hmelo-Silver, C. E., Glazewski, K. D., Ottenbreit-Leftwich, A., Kim, J., Johnson, V., Svetina Valdivia, D. S., Mott, B., & Lester, J. (2024). Validating a hypothetical learning progression to support upper elementary school students to learn and apply artificial intelligence concepts. In *Proceedings of the 18th International Conference of the Learning Sciences* (pp. 178–185). International Society of the Learning Sciences. <https://doi.org/10.22318/icls2024.829130>

Dai, Y. (2023). Negotiation of epistemological understandings and teaching practices between primary teachers and scientists about artificial intelligence in professional development. *Research in Science Education*, 53(3), 577–591. <https://doi.org/10.1007/s11165-022-10072-8>

Getenet, S. (2024). Pre-service teachers and ChatGPT in multistrategy problem-solving: Implications for mathematics teaching in primary schools. *International Electronic Journal of Mathematics Education*, 19(1), Article em0766. <https://doi.org/10.29333/iejme/14141>

Guanga Inca, U. R., Bauz, A. C., Lozada Lozada, R. F., Reinoso Llantui, M. del C., & Paz Bravo, R. B. (2024). Desafíos de la educación para la implementación de la inteligencia artificial. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 3588–3602. https://doi.org/10.37811/cl_rcm.v8i3.11576

Holmes, W., Bialik, M., & Fadel, C. (2019). Artificial intelligence in education: Promises and implications for teaching and learning. Center for Curriculum Redesign.

Huang, C., & Yu, H. (2024). Technological dialogue and intelligent generation: An empirical study of primary Chinese teachers using generative AI for lesson preparation. In *Proceedings of the 2024 International Conference on Intelligent Education and Computer Technology* (pp. 606–611). Association for Computing Machinery. <https://doi.org/10.1145/3687311.3687419>

Huang, S. (2021). Design and development of educational robot teaching resources using artificial intelligence technology. *International Journal of Emerging Technologies in Learning*, 16(5), 5–11. <https://doi.org/10.3991/ijet.v16i05.20311>

Jeon, E.-Y. (2025). Urban and rural students' experiences with AI PengTalk in English learning: A comparative case study. *English Teaching*, 80(3), 125–147. <https://doi.org/10.15858/engtea.80.3.202509.125>

Jiang, J., & Li, X. (2023). A research on wisdom classroom teaching supported by virtual reality: Take the primary

school science “Causes and functions of earthquakes” as an example. In *International Conference on Computer Science and Education* (pp. 575–584). Springer Nature Singapore. https://doi.org/10.1007/978-981-99-2446-2_52

Kim, J., & Wargo, E. (2025). Empowering educational leaders for AI integration in rural STEM education: Challenges and strategies. *Frontiers in Education*, 10, Article 1567698. <https://doi.org/10.3389/feduc.2025.1567698>

Kızıltaş, Y. (2025). Integration of artificial intelligence (AI) into primary school students’ writing skills: The impact of ChatGPT on creative writing and writing self-efficacy. *Journal of Educational Computing Research*, 63(7–8), 1717–1747. <https://doi.org/10.1177/07356331251365187>

Lee, S., Mott, B., Ottenbreit-Leftwich, A., Scribner, A., Taylor, S., Park, K., Rowe, J., Glazewski, K., Hmelo-Silver, C. E., & Lester, J. (2021). AI-infused collaborative inquiry in upper elementary school: A game-based learning approach. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(17), 15591–15599. <https://doi.org/10.1609/aaai.v35i17.17836>

Li, M., & Manzari, E. (2025). AI utilization in primary mathematics education: A case study from a southwestern Chinese city. *Education and Information Technologies*, 30, 11717–11750. <https://doi.org/10.1007/s10639-025-13315-z>

Li, M., & Zhang, H. (2024). A study on the behavioral intention of primary and secondary school teachers using generative artificial intelligence in teaching. In *Proceedings of the 2024 9th International Conference on Distance Education and Learning* (pp. 35–41). Association for Computing Machinery. <https://doi.org/10.1145/3675812.3675870>

Liu, J., Sun, D., Sun, J., Wang, J., & Yu, P. L. H. (2025). Designing a generative AI-enabled learning environment for mathematics word problem solving in primary schools: Learning performance, attitudes and interaction. *Computers and Education: Artificial Intelligence*, 9, Article 100438. <https://doi.org/10.1016/j.caeai.2025.100438>

Mokoena, O. P., & Seeletse, S. M. (2025). AI in rural classrooms: Challenges and perspectives from South African educators. *International Journal of Current Educational Studies*, 4(2), 30–52. <https://doi.org/10.46328/ijces.199>

Montiel-Ruiz, F. J., & López Ruiz, M. (2023). Inteligencia artificial como recurso docente en un colegio rural agrupado. *RiiTE Revista Interuniversitaria de Investigación en Tecnología Educativa*, (15), 28–40. <https://doi.org/10.6018/riite.592031>

Mujica-Sequera, R. M. (2024). Clasificación de las herramientas de la inteligencia artificial en la educación. *Revista Tecnológica-Educativa Docentes 2.0*, 17(1), 31–40. <https://doi.org/10.37843/rted.v17i1.513>

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, Article n71. <https://doi.org/10.1136/bmj.n71>

Sperling, K., Stenliden, L., Nissen, J., & Heintz, F. (2022). Still w(AI)ting for the automation of teaching: An exploration of machine learning in Swedish primary education using actor-network theory. *European Journal of Education*, 57(4), 584–600. <https://doi.org/10.1111/ejed.12526>

Taşdelen, O., & Bodemer, D. (2025). Generative AI in the classroom: Effects of context-personalized learning material and tasks on motivation and performance. *International Journal of Artificial Intelligence in Education*, 35(5), 3049–3070. <https://doi.org/10.1007/s40593-025-00491-9>

UNESCO. (2024). El uso de la IA en la educación: decidir el futuro que queremos. <https://www.unesco.org/es/articles/el-uso-de-la-ia-en-la-educacion-decidir-el-futuro-que-queremos>

Uribe-Zapata, A., Zambrano-Acosta, J. F., & Cano-Vásquez, L. M. (2023). Usos educativos de TIC en docentes rurales de Colombia. *Revista de Investigación, Desarrollo e Innovación*, 13(2), 287–298. <https://doi.org/10.19053/20278306.v13.n2.2023.16834>

Uğraş, H., Uğraş, M., Papadakis, S., & Kalogiannakis, M. (2024). ChatGPT-supported education in primary schools: The potential of ChatGPT for sustainable practices. *Sustainability*, 16(22), Article 9855. <https://doi.org/10.3390/su16229855>

Walan, S. (2025). Primary school students’ perceptions of artificial intelligence—for good or bad. *International Journal of Technology and Design Education*, 35(1), 25–40. <https://doi.org/10.1007/s10798-024-09898-2>

Yuan, Y. J. (2024). An empirical study of the efficacy of AI chatbots for English as a foreign language learning in primary education. *Interactive Learning Environments*, 32(10), 6774–6789. <https://doi.org/10.1080/10494820.2023.2282112>

Zheng, W., & Tse, A. W. C. (2023). The impact of generative artificial intelligence-based formative feedback on the mathematical motivation of Chinese grade 4 students: A case study. In *2023 IEEE International Conference on Teaching, Assessment and Learning for Engineering* (pp. 1–8). IEEE. <https://doi.org/10.1109/TALE56641.2023.10398319>

Anexo A. Matriz de los 30 estudios incluidos

Las Tablas A1 y A2 permiten rastrear las características del corpus y sustentan el análisis temático presentado en los resultados. La Tabla A1 reúne la identificación y el diseño de los estudios; la Tabla A2 sintetiza sus principales hallazgos y el aporte al tema. Ambas tablas contienen exclusivamente los 30 estudios incluidos en la revisión sistemática; las fuentes conceptuales, metodológicas y normativas externas no se incorporaron.

Tabla A1. Caracterización metodológica de los 30 estudios incluidos

Autor(es)	Año y país	Objetivo	Metodología y muestra o contexto
Aparicio-Gómez y Aparicio-Gómez	2024 Colombia / alcance internacional	Examinar la innovación educativa asociada con sistemas de aprendizaje adaptativo impulsados por IA.	Artículo de revisión y reflexión analítica. Literatura sobre plataformas adaptativas y personalización.
Bolaño-García y Duarte-Acosta	2024 Colombia / alcance internacional	Sintetizar los usos, tendencias y desafíos de la IA en educación.	Revisión sistemática de literatura. Publicaciones educativas en distintos niveles y contextos.
Carbonell Bernal y Hernández Prados	2024 España / alcance internacional	Analizar el impacto de los sistemas de tutoría inteligente en el aprendizaje.	Revisión sistemática. Estudios de tutoría inteligente en escenarios educativos.
Guanga Inca et al.	2024 Ecuador / alcance latinoamericano	Identificar desafíos educativos para la implementación de la IA.	Revisión documental de enfoque descriptivo. Instituciones educativas y políticas de integración tecnológica.
Montiel-Ruiz y López Ruiz	2023 España	Explorar la IA como recurso docente en un colegio rural agrupado.	Estudio de caso educativo. Docentes y práctica pedagógica en escuela rural agrupada.
Mujica-Sequera	2024 Alcance internacional	Clasificar herramientas de IA utilizadas en educación.	Ensayo analítico con método inductivo y revisión documental. Herramientas generativas, adaptativas, evaluativas y analíticas.
Uribe-Zapata et al.	2023 Colombia	Caracterizar los usos educativos de TIC por docentes rurales colombianos.	Estudio empírico descriptivo. Docentes rurales de Colombia.
Castro et al.	2025 Chile	Analizar desafíos y oportunidades percibidos por docentes rurales de primaria al integrar IA.	Métodos mixtos convergentes; encuesta cerrada y abierta. 45 docentes rurales que participaron en formación sobre integración de IA.
Jeon	2025 Corea del Sur	Comparar experiencias urbanas y rurales con la aplicación de inglés basada en IA en Pengl Talk.	Estudio de caso comparativo con encuestas, registros de uso y análisis cualitativo. Estudiantes de primaria de una escuela urbana y una rural.
Mokoena y Seeletse	2025 Sudáfrica	Comprender perspectivas docentes sobre IA en aulas rurales y desigualdad digital.	Estudio cualitativo basado en entrevistas y análisis temático. Educadores de escuelas rurales sudafricanas.
Kim y Wargo	2025 Estados Unidos	Examinar la integración de IA en educación STEM rural desde el liderazgo escolar.	Métodos mixtos: encuesta y grupos focales. Líderes educativos de distritos K-12, principalmente rurales.
Bagabas	2025 Arabia Saudita	Analizar perspectivas docentes sobre IA y aprendizaje personalizado para estudiantes	Estudio descriptivo mediante encuesta. Docentes de primaria y atención a necesidades

		antes con dificultades de aprendizaje.	educativas diversas.
Batubara et al.	2025 Indonesia	Examinar percepciones y preparación docente para integrar IA móvil en primaria.	Encuesta cuantitativa de preparación y actitudes. Docentes de educación elemental.
Chakraborty et al.	2024 Estados Unidos	Validar una progresión de aprendizaje para que estudiantes de primaria comprendan y apliquen conceptos de IA.	Investigación basada en diseño y validación de progresión de aprendizaje. Estudiantes de grados superiores de primaria y docentes.
Dai	2023 China	Analizar cómo docentes de primaria negocian conocimientos y prácticas sobre IA durante formación profesional.	Estudio cualitativo de desarrollo profesional. Docentes de primaria y científicos participantes en formación sobre IA.
Getenet	2024 Australia	Examinar ChatGPT como apoyo para estrategias múltiples de resolución de problemas matemáticos.	Intervención exploratoria con análisis de producciones y percepciones. Docentes en formación con implicaciones para matemática en primaria.
Huang y Yu	2024 China	Examinar el uso de IA generativa por docentes de primaria para preparar clases.	Estudio empírico de interacción docente-IA. Docentes chinos de primaria y tareas de diseño de lecciones.
Huang	2021 China	Diseñar y evaluar recursos de enseñanza con robot educativo e IA.	Diseño y evaluación de intervención educativa. Clases escolares con robot educativo.
Jiang y Li	2023 China	Proponer una clase inteligente para ciencias de primaria apoyada por IA, IoT y realidad virtual.	Diseño de modelo y estudio de caso didáctico. Enseñanza de ciencias en primaria.
Kızıltaş	2025 Turquía	Evaluar el efecto de ChatGPT sobre escritura creativa y autoeficacia.	Diseño cuasiexperimental. Estudiantes de primaria en actividades de escritura.
Lee et al.	2021 Estados Unidos	Diseñar aprendizaje colaborativo basado en juego para conceptos de IA en primaria.	Investigación basada en diseño con indagación colaborativa. Estudiantes de grados superiores de primaria y docentes.
Li y Manzari	2025 China	Comprender la utilización de IA en matemática de primaria desde TPACK y condiciones institucionales.	Estudio de caso. Docentes y escuelas de una ciudad del suroccidente de China.
Li y Zhang	2024 China	Analizar la intención de docentes de primaria y secundaria de usar IA generativa.	Encuesta cuantitativa con análisis de factores de adopción. Docentes de educación básica y media.
Liu et al.	2025 China	Evaluar un entorno de IA generativa para resolver problemas matemáticos verbales.	Intervención comparativa con análisis de rendimiento, actitudes e interacción. Estudiantes de primaria.
Sperling et al.	2022 Suecia	Explorar el uso de aprendizaje automático en educación primaria y las relaciones entre actores.	Estudio cualitativo con teoría del actor-red. Escuelas primarias suecas y prácticas con aprendizaje automático.
Taşdelen y Bodemer	2025 Alemania	Evaluar materiales y tareas matemáticas personalizados por IA generativa.	Diseño experimental en aula. Estudiantes escolares en actividades matemáticas.
Uğraş et al.	2024 Turquía y Grecia	Examinar el potencial de ChatGPT en educación primaria y prácticas sostenibles.	Estudio de percepciones docentes y análisis aplicado. Docentes y escenarios de educación primaria.
Walan	2025 Suecia	Conocer percepciones de estudiantes de primaria sobre beneficios y riesgos de la IA.	Estudio cualitativo de percepciones estudiantiles. Estudiantes de primaria.
Yuan	2024 China	Evaluar la eficacia de chatbots de IA para aprender inglés como lengua extranjera.	Estudio empírico comparativo. Estudiantes de primaria en aprendizaje oral de inglés.
Zheng y Tse	2023 China / Hong Kong	Analizar el efecto de retroalimentación formativa generativa sobre motivación matemática.	Estudio de caso cualitativo. Estudiantes de cuarto grado.

	a.	
--	----	--

Tabla A2. Síntesis de hallazgos y aporte de los estudios incluidos

Autor(es)	Principales hallazgos	Aporte al tema
Aparicio-Gómez y Aparicio-Gómez	La adaptación de contenidos y ritmos puede mejorar la experiencia de aprendizaje, pero exige diseño pedagógico, datos de calidad y supervisión docente.	Delimita la personalización basada en IA y sus condiciones de implementación; evidencia transferible a escuelas rurales.
Bolaño-García y Duarte-Acosta	Predominan aplicaciones de predicción, tutoría, personalización y automatización; persisten retos éticos, formativos y de acceso.	Ofrece un panorama para diferenciar oportunidades pedagógicas de afirmaciones deterministas sobre la IA.
Carbonell Bernal y Hernández Prados	Los sistemas favorecen retroalimentación, práctica adaptativa y rendimiento, aunque los efectos dependen del diseño, duración y acompañamiento.	Sustenta el vínculo entre retroalimentación automatizada, personalización y motivación.
Guanga Inca et al.	La adopción está condicionada por infraestructura, competencias digitales, ética, formación y gobernanza institucional.	Refuerza la justificación del problema y la necesidad de una implementación contextualizada.
Montiel-Ruiz y López Ruiz	La IA apoya planificación y creación de recursos, pero requiere mediación docente, conectividad y criterios de selección.	Evidencia rural directa sobre usos realistas de IA por parte del profesorado.
Mujica-Sequera	La IA educativa comprende sistemas con capacidad de inferencia, generación, recomendación o adaptación, no cualquier recurso digital.	Permite diferenciar IA educativa de TIC, plataformas digitales y tecnología educativa general.
Uribe-Zapata et al.	El uso pedagógico está mediado por conectividad, disponibilidad de equipos, formación y pertinencia de los recursos.	Aporta la base contextual para interpretar la viabilidad de la IA en ruralidad colombiana.
Castro et al.	La accesibilidad de recursos y el desarrollo profesional son los principales factores para reducir la brecha digital.	Evidencia rural directa que vincula IA, I-TPACK, alfabetización en IA y formación docente.
Jeon	La gamificación favoreció motivación, pero el grupo rural enfrentó menor apoyo, alfabetización digital limitada y restricciones de acceso.	Demuestra que la motivación con IA depende de infraestructura, guía docente y soporte contextual.
Mokoena y Seeletse	Existe interés por la IA, pero conectividad, equipos, formación y adecuación cultural limitan la adopción.	Evidencia rural directa sobre barreras estructurales y necesidad de diseño inclusivo.
Kim y Wargo	Los líderes valoran la personalización, pero identifican riesgos de privacidad, ausencia de metas, conectividad deficiente y falta de formación.	Evidencia rural directa para orientar liderazgo, políticas, desarrollo profesional y equidad.
Bagabas	Se reconocen beneficios en personalización y compromiso; se señalan costos y formación insuficiente.	Aporta criterios de inclusión y accesibilidad transferibles a grupos heterogéneos rurales.
Batubara et al.	Las actitudes son favorables, pero la preparación práctica es desigual y depende de apoyo institucional y formación.	Sustenta la necesidad de formación situada antes de escalar herramientas móviles en ruralidad.
Chakraborty et al.	Se observaron avances por niveles, aunque el progreso varió con la experiencia docente y las condiciones del aula.	Muestra que la alfabetización en IA requiere secuencias didácticas y andamiaje docente.
Dai	La apropiación mejora cuando se conectan conceptos técnicos, currículo, práctica y reflexión pedagógica.	Fortalece la recomendación de formación docente prolongada y vinculada al aula.

Getenet	La herramienta amplía estrategias y discusión, pero produce errores y necesita verificación y adaptación por edad.	Sustenta el uso crítico de IA generativa y la supervisión de resultados.
Huang y Yu	Mejora la variedad y personalización de las propuestas, pero exige alfabetización de datos y control de calidad.	Aporta recomendaciones para planificación docente en entornos con recursos limitados.
Huang	Aumentaron atención, iniciativa y rendimiento frente a clases tradicionales; persistieron costos y necesidades de capacitación.	Relaciona interacción adaptativa con compromiso y muestra barreras de sostenibilidad.
Jiang y Li	El modelo favorece indagación y participación, pero requiere infraestructura y evaluación más profunda.	Advierte que los diseños sofisticados son difíciles de transferir sin recursos mínimos.
Kızıldaş	La retroalimentación con IA mejoró resultados y autoeficacia; se requiere guía para evitar dependencia.	Aporta evidencia específica sobre motivación, autoeficacia y retroalimentación generativa.
Lee et al.	El enfoque fue atractivo y compatible con problemas auténticos; necesita andamiaje y apoyo docente.	Muestra cómo la IA puede apoyar participación sin sustituir la mediación humana.
Li y Manzari	La adopción depende de conocimiento pedagógico-tecnológico, actitudes, infraestructura y apoyo institucional.	Integra factores individuales y sistémicos para explicar la implementación.
Li y Zhang	La utilidad percibida, el esfuerzo, la influencia social y las condiciones facilitadoras explican la intención de uso.	Orienta programas de formación, soporte y selección de herramientas.
Liu et al.	Se observaron mejoras en resolución de problemas, interés y desarrollo de estrategias; existe sensibilidad a instrucciones y riesgo de dependencia.	Vincula personalización y motivación con resultados específicos de aprendizaje.
Sperling et al.	La automatización no elimina el trabajo docente; redistribuye decisiones, responsabilidades y dependencias tecnológicas.	Sustenta una lectura crítica de la IA como ensamblaje sociotécnico, no como solución autónoma.
Taşdelen y Bodemer	La personalización contextual aumentó motivación intrínseca, interés y desempeño frente a tareas estándar.	Evidencia el potencial motivacional de la personalización, condicionado por calidad y seguridad del contenido.
Uğraş et al.	Se valora el apoyo a planificación y recursos, pero preocupan alucinaciones, privacidad y formación de docentes y familias.	Aporta criterios de sostenibilidad, alfabetización y regulación del uso generativo.
Walan	Los estudiantes reconocen apoyo práctico, pero expresan inquietud por privacidad, velocidad del cambio y efectos sociales.	Incorpora la voz estudiantil y la necesidad de alfabetización ética apropiada para la edad.
Yuan	Mejoraron la competencia oral y la disposición a comunicarse; se requieren ajustes, privacidad y orquestación docente.	Vincula interacción conversacional, motivación y aprendizaje adaptativo.
Zheng y Tse	Aumentaron motivación, confianza, participación y actitudes positivas; el tamaño de muestra limitó la generalización.	Aporta evidencia directa sobre retroalimentación de IA y motivación académica.