

## *Filtros educativos basados en inteligencia artificial: transformaciones en la enseñanza y la interacción docente-estudiante*

*Educational filters based on artificial intelligence: transformations in teaching and teacher-student interaction*

**Fortunato Contreras Contreras**

[fcontrerasc@unmsm.edu.pe](mailto:fcontrerasc@unmsm.edu.pe)

<https://orcid.org/0000-0001-6060-0321>

Universidad Nacional Mayor de San Marcos.  
Lima, Perú

**Julio Cesar Olaya Guerrero**

[jolayag@unmsm.edu.pe](mailto:jolayag@unmsm.edu.pe)

<https://orcid.org/0000-0002-4273-3654>

Universidad Nacional Mayor de San Marcos.  
Lima, Perú

Artículo recibido 31 de julio de 2025 / Arbitrado 29 de agosto de 2025 / Aceptado 02 de octubre 2025 / Publicado 30 de octubre de 2025

<https://doi.org/10.62319/simonrodriguez.v.5i10.58>

### RESUMEN

Los filtros educativos basados en IA median el acceso, secuenciación, evaluación y apoyo a estudiantes mediante datos de aprendizaje. El objetivo de este estudio es analizar la evolución, efectividad y transformaciones pedagógicas de los filtros educativos basados en inteligencia artificial y su impacto en la enseñanza y la interacción docente-estudiante. El enfoque es cualitativo, se realizó una revisión narrativa-analítica de evidencia empírica, ensayos controlados aleatorizados (RCT), revisiones sistemáticas y marcos institucionales. Los resultados indican mejora significativa en aprendizaje y compromiso estudiantil con eficiencia temporal. El RCT en educación superior muestra medianas superiores con tutor de IA (4.5 vs 3.5), mayor compromiso (4.1 vs 3.6) y menor tiempo (49 vs 60 min). Los sistemas tutores inteligentes en K-12 demuestran efectos positivos en autorregulación. Los pipelines multimodales reportan alta especificidad (99.06%) con sensibilidad variable. Se concluye que los filtros educativos constituyen infraestructura transformadora que personaliza y optimiza el aprendizaje cuando preservan interacción humana y se acompañan de marcos de gobernanza robustos.

### Palabras clave:

Educación superior;  
Filtros educativos;  
Inteligencia artificial;  
Sistemas tutores  
inteligentes

### ABSTRACT

AI-based educational filters mediate student access, sequencing, assessment, and support using learning data. This study aims to analyze the evolution, effectiveness, and pedagogical transformations of AI-based educational filters and their impact on teaching and teacher-student interaction. The approach is qualitative, employing a narrative-analytical review of empirical evidence, randomized controlled trials (RCTs), systematic reviews, and institutional frameworks. The results indicate significant improvements in learning and student engagement with time efficiency. The RCT in higher education shows higher medians with AI tutors (4.5 vs. 3.5), greater engagement (4.1 vs. 3.6), and shorter time (49 vs. 60 min). Intelligent tutoring systems in K-12 demonstrate positive effects on self-regulation. Multimodal pipelines report high specificity (99.06%) with variable sensitivity. The study concludes that educational filters constitute transformative infrastructure that personalizes and optimizes learning when they preserve human interaction and are accompanied by robust governance frameworks.

### Keywords:

Higher education;  
Educational filters;  
Artificial intelligence;  
Intelligent tutoring  
systems

## INTRODUCCIÓN

La irrupción de modelos de inteligencia artificial de gran escala y la generalización de herramientas generativas han convertido los entornos educativos en sistemas mediado-algorítmicos. En este contexto, los filtros educativos basados en IA se entienden como componentes que, a partir de datos de aprendizaje, median y ajustan el acceso, la secuenciación, la evaluación y el apoyo a estudiantes en función de datos de aprendizaje. Estos filtros inciden directamente sobre la médula de los procesos formativos: qué se enseña, cómo se aprende, cuándo se evalúa y de qué manera se interviene para sostener el progreso académico. A diferencia de aplicaciones administrativas o de gestión, estos filtros afectan directamente la experiencia formativa, la agencia estudiantil, los resultados de aprendizaje y la relación docente-estudiante, configurando una infraestructura pedagógica con efectos sistémicos en la toma de decisiones didácticas y en la equidad de trayectorias educativas (Chen et al., 2022).

Esta introducción persigue cuatro objetivos integrados. Primero, establecer un marco conceptual y una taxonomía operativa de filtros educativos de IA, anclados en evidencia y funciones docentes. Segundo, reconstruir la evolución histórica que conduce desde los sistemas tutores inteligentes y la analítica de aprendizaje hasta la IA generativa y los pipelines multimodales de moderación y recomendación. Tercero, examinar la problemática actual -técnica, ética, de equidad y sostenibilidad- con base en marcos de gobernanza y guías institucionales vigentes. Cuarto, delimitar el alcance geográfico y temático del estudio, justificar su necesidad y formular objetivos específicos y medibles, alineados con prioridades de investigación y política educativa 2019–2025.

Desde una perspectiva funcional, los filtros educativos de IA operan como “válvulas” y “engranajes” pedagógicos. Como válvulas, controlan el flujo de contenidos y actividades (clasificación, restricción, priorización); como engranajes, encadenan secuencias y recomendaciones que convierten datos en decisiones didácticas adaptativas. Su relevancia radica en que modulan exposición, andamiaje, retroalimentación y evaluación, con consecuencias directas en el rendimiento académico, el compromiso estudiantil y el bienestar. En contraste con herramientas de gestión, como el registro de asistencia o la logística institucional, los filtros educativos se insertan en la interacción pedagógica y evaluativa, afectando la construcción del conocimiento, la agencia del estudiante y la mediación docente.

La génesis contemporánea de estos filtros combina tres tradiciones convergentes. La primera es la de los sistemas tutores inteligentes (STI), que modelan el estado del estudiante y adaptan contenidos en dominios estructurados (Lin et al., 2023). La segunda proviene de la analítica de aprendizaje y la minería de datos educativos, que detectan patrones de comportamiento y rendimiento para informar intervención temprana y personalización (Artificial intelligence in education, 2024). La tercera emerge de la moderación y clasificación de contenidos en plataformas sociales, cuyos pipelines multimodales, reconocimiento de voz (ASR), visión por computador con reconocimiento óptico de caracteres (OCR) y detección de objetos, seguidos de clasificación por modelos de lenguaje grandes (LLM) y verificación humana, ofrecen arquitecturas transferibles a la curaduría y el control de calidad en educación (Sharp et al., 2025; Al Faraby et al., 2024).

La convergencia de estas corrientes, catalizada por el avance de la IA generativa, ha configurado un ecosistema educativo donde filtros de contenido, secuencia/recomendación, evaluación/autograding y riesgo/estudiantes se articulan con funciones docentes específicas —facilitación, curaduría, diseño de experiencias y evaluación— y con constructos de interacción pedagógica como andamiaje, retroalimentación formativa, autorregulación y aprendizaje activo (Chen et al., 2022). Este entramado funcional redefine el rol docente y la experiencia estudiantil, al integrar decisiones automatizadas en momentos clave del proceso formativo.

En términos operativos, los propósitos de estos filtros se despliegan en cuatro direcciones interrelacionadas. En primer lugar, la seguridad y calidad del contenido se aborda mediante procesos de moderación y curación multimodal de materiales generados por estudiantes y docentes, utilizando métricas como la precisión, la sensibilidad, la especificidad y la concordancia entre evaluadores (Sharp et al., 2025). En segundo lugar, la personalización de rutas de aprendizaje se logra a través de sistemas de recomendación y mecanismos adaptativos que ajustan la dificultad, el ritmo y los recursos, en estrecha relación con indicadores de progreso, retención y satisfacción (Adaptive Learning Using Artificial Intelligence, 2023; Chen et al., 2022).

En tercer lugar, la automatización evaluativa y la retroalimentación inmediata se implementan mediante sistemas de autocalificación en tareas tanto objetivas como abiertas, donde la exactitud de la calificación y los tiempos de retorno constituyen métricas clave, integradas en sistemas tutores inteligentes y plataformas de aprendizaje (Chen et al., 2022; A Systematic Review of AI-driven ITS, 2025). Finalmente, la detección de riesgo y la intervención temprana se fundamentan en modelos explicables que clasifican a los estudiantes según su comportamiento y rendimiento, utilizando métricas como el AUC y la precisión, con evidencia de impacto en alertas y segmentaciones accionables (Vinoth et al., 2025; Course Success Prediction, 2024; Artificial Intelligence in Education, 2024).

Desde una perspectiva geográfica, la evidencia muestra patrones diferenciados en cuanto a producción científica, aplicación institucional y marcos normativos. América del Norte se caracteriza por concentrar ensayos controlados en educación superior, como los estudios que demuestran que los tutores de IA superan al aprendizaje activo, además de desarrollar marcos de política educativa centrados en el uso responsable y la alfabetización algorítmica (Kestin et al., 2025; U.S. Department of Education, 2023).

Por su parte, Europa enfatiza la regulación y la rendición de cuentas, con iniciativas como el EU AI Act y debates sobre su eficacia en el ámbito universitario, junto con programas de alfabetización en IA y marcos institucionales frente a los desafíos de la IA generativa (Artificial Intelligence in Education, 2025; Higher Education Act for AI, 2025; The Development of Policies on Generative AI, 2025).

En contraste, Asia-Pacífico lidera la producción en K-12 y educación superior, con bibliometría que identifica clusters temáticos (aprendizaje impulsado por IA, educación lingüística con IA, currículo de IA, aplicaciones de chatbots y herramientas de IA, aprendizaje adaptativo y análisis de aprendizaje, IA generativa en aula), y redes de coautoría en Asia Oriental (China, Hong Kong, Taiwán, Corea del Sur) (Irwanto, 2025).

En el caso de América Latina, se observa un momento de expansión marcado por desafíos estructurales como las brechas digitales, necesidades de formación docente y gobernanza. No obstante, emergen iniciativas relevantes como la evaluación de la preparación institucional para la IA en México y llamados a la cooperación regional para fortalecer la seguridad y la gobernanza tecnológica. Estos avances sitúan a la región en un punto crítico para el diseño de políticas públicas y el despliegue responsable de tecnologías educativas (Acevedo et al., 2025; ILIA 2024, 2024; UNESCO Presents, 2023; Regional Cooperation, 2024; The Future of AI in Education, 2023).

En síntesis, América del Norte se distingue por su enfoque experimental y normativo, Europa por su énfasis regulatorio y ético, Asia-Pacífico por su liderazgo en investigación aplicada, con fuerte presencia de aprendizaje adaptativo, chatbots y curación de contenidos. Y, América Latina por su impulso emergente en medio de desafíos estructurales. Esta diversidad geográfica revela no solo diferencias en el ritmo de adopción, sino también en las prioridades epistemológicas, institucionales y sociales que configuran el uso de filtros educativos basados en inteligencia artificial.

La arquitectura conceptual de los filtros educativos, se articula de manera directa con funciones docentes y constructos pedagógicos. En este entramado, los filtros de contenido se orientan hacia la curaduría y la seguridad, mediante procesos de moderación de producciones estudiantiles y clasificación de materiales según el tipo de pregunta, utilizando métricas técnicas como precisión, sensibilidad, especificidad y consistencia inter-evaluador. Estos procesos, sin embargo, requieren una mediación humana sistemática (human-in-the-loop) que garantice la legitimidad pedagógica y la pertinencia contextual.

Por su parte, los filtros de secuencia y recomendación, personalizan rutas y recursos a través de mecanismos de aprendizaje adaptativo y sistemas de recomendación, cuyas métricas de progreso, finalización y retención se vinculan estrechamente con el andamiaje cognitivo y la zona de desarrollo próximo. En paralelo, los filtros de evaluación y autocalificación automatizan la retroalimentación en tareas objetivas y abiertas, integrándose en sistemas tutores inteligentes (STI) y plataformas educativas, con indicadores de exactitud y tiempos de retorno que inciden directamente en la experiencia formativa. Finalmente, los filtros de riesgo y clasificación estudiantil permiten detectar patrones de comportamiento y rendimiento para activar intervenciones tempranas, mediante modelos explicables que habilitan segmentaciones accionables, evaluadas con métricas como AUC, precisión y utilidad de intervención.

La evolución histórica de estos filtros refleja una trayectoria que transita desde el modelado del estudiante hacia formas más complejas de mediación algorítmica. Entre los hitos relevantes se encuentra el panorama inicial de la IA en educación superior (2019), que estableció categorías funcionales y abrió el debate sobre sus implicaciones. Posteriormente, la revisión sistemática sobre IA en STEM (2022) consolidó áreas clave como la predicción, los sistemas tutores inteligentes, la automatización evaluativa y el análisis de comportamiento.

En 2023 emergieron marcos institucionales de política educativa, mientras que la investigación sobre IA en STI, comenzó a orientarse hacia una educación sostenible con énfasis en la explicabilidad y el diseño centrado en el ser humano. El año 2024 marcó un punto de inflexión con la publicación de revisiones sistemáticas sobre IA en educación y, de manera crucial, con la Recomendación de la UNESCO sobre ética de la IA. Finalmente, 2025 ha sido decisivo: se ha demostrado empíricamente que los tutores de IA superan al aprendizaje activo en ensayos controlados, se han validado pipelines multimodales para moderación con verificación humana, se ha desarrollado el sistema SCS-B para clasificación estudiantil, se han publicado bibliometrías especializadas en K-12, y se han consolidado marcos de gobernanza como HEAT-AI y el EU AI Act aplicados específicamente al ámbito educativo.

La implementación de filtros educativos basados en la IA plantea retos multidimensionales que deben ser abordados con responsabilidad institucional y sensibilidad pedagógica. En el plano técnico, se identifican retos como la comprensión contextual, la dependencia de datos, el costo computacional y la eficiencia operativa, lo que exige ajustes finos con datos educativos, grafos de conocimiento, aprendizaje mixto y verificación humana (Alia et al., 2024; Chen et al., 2022). Desde una perspectiva pedagógica, persiste el riesgo de mecanización y la limitación de la creatividad, lo que demanda el diseño de prompts y tareas centradas en el proceso, la evaluación formativa y la preservación de la interacción significativa (Alia et al., 2024; Chen et al., 2022).

En el plano ético, se destacan preocupaciones sobre la privacidad, sesgo e integridad académica, que requieren auditorías de sesgo, trazabilidad de datos y políticas claras de gobernanza y uso responsable (UNESCO Recommendation on the Ethics, 2024; U.S. Department of Education, 2023; AI Governance in Latin America, 2024). En términos de equidad, la brecha digital y la adopción desigual; demandan inversión en infraestructura, formación docente y marcos inclusivos que garanticen acceso justo y contextualizado (Acevedo et al., 2025; ILIA 2024, 2024; Regional cooperation, 2024; The future of AI in education, 2023). Finalmente, en cuanto a sostenibilidad, el impacto ambiental del cómputo exige optimización energética y

directrices de uso responsable que consideren el equilibrio entre innovación y preservación ecológica (Alia et al., 2024; UNESCO Recommendation on the Ethics, 2024).

Para orientar decisiones de implementación, emergen cinco dimensiones críticas que articulan beneficios, desafíos y estrategias. En el plano técnico, si bien la personalización, automatización y rutas adaptativas representan ventajas claras, persisten retos en comprensión contextual, la dependencia de datos y costos operativos. Por ello, resulta imprescindible avanzar hacia procesos de fine-tuning con datos educativos, integración de grafos de conocimiento, aprendizaje mixto y verificación humana sistemática, como condiciones mínimas para una implementación ética y pedagógicamente legítima.

Desde la perspectiva pedagógica, los beneficios asociados al feedback inmediato, la autorregulación y el compromiso estudiantil conviven con riesgos de mecanización y creatividad limitada. Para mitigar estos riesgos, se recomienda el diseño de prompts creativos, tareas centradas en el proceso y estrategias de evaluación formativa que preserven la interacción significativa entre docentes y estudiantes. En este sentido, los filtros educativos deben ser comprendidos no solo como herramientas técnicas, sino como mediadores de vínculos pedagógicos que requieren sensibilidad didáctica.

La dimensión ética, aunque amplía el acceso y el acompañamiento a estudiantes, plantea desafíos relacionados con el sesgo algorítmico, la privacidad de los datos y la integridad académica. Por ello, se vuelve imprescindible implementar auditorías de sesgo, mecanismos de gobernanza de datos y políticas institucionales claras que orienten el uso responsable de la inteligencia artificial en contextos educativos. Estas medidas, además de garantizar transparencia, fortalecen la legitimidad de los procesos automatizados.

En cuanto a la equidad, si bien se promueve un soporte diversificado, continúan brechas digitales y desigualdades en la adopción de tecnologías, especialmente en regiones con infraestructura limitada. Esto exige una inversión sostenida en conectividad, formación docente y marcos inclusivos que aseguren el acceso justo y contextualizado a los beneficios de la IA educativa. Finalmente, la dimensión de sostenibilidad interpela a las instituciones a considerar el impacto ambiental del cómputo intensivo, promoviendo la optimización energética y el desarrollo de directrices para un uso responsable que no comprometa los equilibrios ecológicos.

Finalmente, la necesidad de este estudio se fundamenta en cuatro razones estratégicas. En primer lugar, la brecha de evidencia: la concentración de investigaciones en educación superior y disciplinas STEM, junto con la escasez de ensayos controlados longitudinales en K-12 y áreas no STEM, limita la posibilidad de generalizar hallazgos y diseñar políticas basadas en evidencia robusta (Artificial Intelligence in Education, 2024; Irwanto, 2025). En segundo lugar, la heterogeneidad de métricas y contextos: la ausencia de estándares comunes en precisión, sensibilidad, especificidad, equidad y AUC dificulta la comparación entre sistemas y la evaluación de su impacto real (Adaptive Learning Using Artificial Intelligence, 2023).

En tercer lugar, la urgencia de gobernanza: los marcos éticos internacionales (UNESCO) y las guías institucionales (OET, ANEP, EDUTEC) demandan una implementación responsable, con auditorías, trazabilidad y mecanismos de rendición de cuentas en despliegues reales (UNESCO Recommendation on the Ethics, 2024; U.S. Department of Education, 2023; ANEP, 2024; EDUTEC, 2024). En cuarto lugar, la oportunidad metodológica: la transferencia validada de pipelines multimodales desde plataformas sociales hacia entornos educativos, con verificación humana y métricas técnicas, ofrece un potencial significativo para fortalecer la moderación de contenido y la curaduría pedagógica (Sharp et al., 2025; AI vs. Human Moderators, 2025; Al Faraby et al., 2024).

En consecuencia, el objetivo de este estudio es analizar la evolución, efectividad y transformaciones pedagógicas de los filtros educativos basados en inteligencia artificial y su impacto en la enseñanza y la

interacción docente-estudiante, en los niveles de educación superior, STEM y K-12 durante el período 2019–2025. Esta delimitación permite examinar tanto el desarrollo técnico como las implicaciones formativas de dichos filtros, en contextos diversos y bajo marcos institucionales diferenciados, contribuyendo a una comprensión crítica y situada de su impacto en los procesos educativos contemporáneos.

## **METODOLOGÍA**

Para el desarrollo de este estudio se adopta una revisión narrativa-analítica con enfoque cualitativo, orientada a integrar, interpretar y contextualizar evidencia diversa sobre filtros educativos basados en inteligencia artificial (IA) en educación superior, STEM y K-12, con atención a contextos iberoamericanos. Este enfoque evita la agregación estadística, privilegiando una lectura situada y coherente en un campo caracterizado por la rápida evolución de tipologías, métricas y funciones, con impacto directo en la enseñanza y la interacción docente-estudiante.

El período de revisión abarca desde 2019–2025 e incorpora estudios empíricos, revisiones sistemáticas y marcos institucionales que permiten comprender definiciones, tipologías, efectividad pedagógica, transformación de la relación docente–estudiante, beneficios, desafíos y perspectivas de gobernanza. La elección metodológica responde a la heterogeneidad de diseños (RCT, estudios de caso, marcos institucionales) y métricas (precisión, sensibilidad, especificidad, AUC, compromiso, motivación, tiempo), lo que justifica una síntesis narrativa en lugar de meta-análisis.

La estrategia de síntesis combina comparaciones directas cuando las métricas lo permiten, análisis temáticos por familia de filtros y contextualización por nivel educativo y región. Para la efectividad pedagógica, se contrastan resultados cuantitativos de RCT y revisiones sistemáticas; en cuanto a la transformación docente-estudiante, se integran marcos institucionales y estudios de caso centrados en mediación y agencia.

En cuanto al protocolo de búsqueda se desarrolló entre marzo y junio de 2025, en siete bases de datos especializadas (Web of Science, Scopus, IEEE Xplore, ERIC, PubMed, PMC y MDPI), con un corpus inicial de 3,817 publicaciones. Se aplicaron términos booleanos combinados (“artificial intelligence”, “educational filters”, “adaptive learning”, “intelligent tutoring”, “automated assessment”) y criterios de inclusión: periodo 2019–2025, publicación indexada con DOI/URL verificable, idioma español/inglés/portugués, estudios revisados por pares, y cobertura temática en cinco dimensiones (definiciones, efectividad pedagógica, desempeño técnico, transformación docente-estudiante, marcos institucionales).

Finalmente, tras las fases de identificación, cribado, elegibilidad e inclusión, se incorporaron 47 estudios: 5 ensayos controlados aleatorizados, 12 revisiones sistemáticas, 30 estudios empíricos y marcos institucionales. La distribución por nivel educativo prioriza educación superior (23 estudios), seguida de STEM (16) y K-12 (8). Geográficamente, predominan América del Norte (19), Europa (15), Asia (8) y la región iberoamericana (5), reflejando tanto la disponibilidad de literatura como los enfoques regionales en el desarrollo de filtros educativos basados en IA.

## **DESARROLLO Y DISCUSIÓN**

A partir del protocolo metodológico definido, se sistematizan a continuación los principales hallazgos derivados del análisis narrativo-analítico.

## Efectividad pedagógica y compromiso estudiantil

El ensayo controlado aleatorizado (RCT) en educación superior que compara un tutor de IA frente a aprendizaje activo reporta mejoras significativas en resultados de aprendizaje y percepciones de compromiso, junto con una reducción del tiempo de dedicación. La mediana de post-prueba en la condición tutor de IA (4.5) supera a la del aprendizaje activo (3.5), con significancia estadística ( $z = -5.6$ ;  $p < 10^{-8}$ ). En compromiso, la condición de IA logra una media superior (4.1 vs 3.6;  $t = -4.5$ ;  $p < 0.0001$ ), y la motivación también mejora (3.4 vs 3.1;  $t = -3.4$ ;  $p < 0.001$ ). La mediana de tiempo es inferior con tutor de IA (49 min) respecto a aprendizaje activo (60 min), con 70% de participantes por debajo de 60 minutos bajo IA, lo que sugiere mayor eficiencia instruccional sin sacrificar logro. En términos de tamaño de efecto, la regresión lineal reporta  $d = 0.63$  y la regresión cuantil  $d = 0.73-1.3$ , indicando beneficios consistentes en la mediana y la cola superior de desempeño estudiantil (Kestin et al., 2025).

En K-12, los sistemas tutores inteligentes (STI) muestran efectos positivos en compromiso, autorregulación y adaptación de dificultad, con heterogeneidad metodológica y variación por contexto. Esta variación aconseja cautela al generalizar resultados y destaca la importancia del diseño instruccional, la formación docente y el alineamiento con objetivos curriculares específicos (A systematic review of AI-driven ITS, 2025).

## Distribución de aplicaciones y patrones en STEM

La revisión sistemática en STEM (2011–2021) identifica seis categorías de aplicaciones de IA: STI (25%), predicción del aprendizaje (22%), detección del comportamiento (21%), automatización evaluativa (13%), robots educativos (9%) y otros (3%). Este patrón revela dos ejes dominantes: personalización (STI) y analítica de aprendizaje. La retroalimentación rápida y la eficiencia en calificación emergen como funcionalidades críticas, mientras que los robots educativos, aunque minoritarios, aportan valor en programación y habilidades socioemocionales (Chen et al., 2022).

## Filtrado multimodal de contenido: desempeño técnico y trade-offs

La transferencia de pipelines desde plataformas sociales hacia entornos educativos ha permitido validar arquitecturas para curaduría y moderación de contenidos. Un pipeline multimodal que integra reconocimiento de voz (ASR), visión por computador (OCR) y clasificación con modelos generativos, apoyado de verificación humana, reporta alta especificidad (99.06%) y sensibilidad variable (82.79% en embarazo; 53.37% en vapeo). La baja concordancia interevaluador (45.38%) evidencia la complejidad semántica de ciertos temas y justifica la mediación humana en decisiones sensibles (Sharp et al., 2025).

## Clasificación de estudiantes por riesgo y analítica de intervención

Los sistemas de clasificación estudiantil (SCS-B) emplean algoritmos híbridos -preprocesamiento, SVD, selección genética y redes neuronales- para segmentar perfiles de riesgo. La alta precisión en validación cruzada permite intervenciones tempranas, recomendaciones personalizadas y asignación eficiente de recursos. No obstante, su implementación exige salvaguardas éticas: explicabilidad, auditorías de sesgo y gobernanza de datos (Vinoth Kumar et al., 2025).

## Implicaciones por nivel educativo

En K-12, la prioridad es la protección, la inclusión y la formación integral. La adopción de STI y filtros de contenido debe acompañarse de lineamientos claros, formación docente en andamiaje y evaluación formativa, y salvaguardas de privacidad. La evidencia sugiere beneficios en compromiso y autorregulación, pero la heterogeneidad metodológica demanda implementaciones piloto con evaluación rigurosa y escalamiento progresivo (A systematic review of AI-driven ITS, 2025; U.S. Department of Education, 2023).

En Educación superior, el foco está en la calidad, la eficiencia y la transformación del diseño instruccional. Los tutores de IA y la automatización evaluativa pueden mejorar resultados y aliviar cargas, mientras que la analítica de aprendizaje permite intervenciones tempranas y personalización. El riesgo de dependencia tecnológica y sesgos requiere marcos de gobernanza, auditorías periódicas y aprendizaje mixto (blended) con mediación docente (The quiet transformation, 2025; U.S. Department of Education, 2023).

En disciplinas STEM, la prioridad es precisión disciplinar, escalabilidad y continuidad. La alta frecuencia de STI, predicción y automatización en STEM habilita mejoras tangibles en aprendizaje y eficiencia, pero exige coherencia con estándares disciplinares, trazabilidad de datos y métricas abiertas de desempeño. La integración con laboratorios, simulaciones y robótica potencia el aprendizaje experiencial, con atención a equidad de acceso (Chen et al., 2022; Artificial intelligence in education, 2024).

### Síntesis metodológica y datos técnicos complementarios

Para completar la presentación de resultados, se incluyen síntesis metodológicas y datos técnicos que complementan los hallazgos principales.

**Tabla 1.** Matriz de métodos narrativo-analíticos

| Dimensión                         | Fuentes                                  | Tipos de                                |                                            |                                                                                                                                                  |
|-----------------------------------|------------------------------------------|-----------------------------------------|--------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------|
|                                   |                                          | evidencia                               | Métricas                                   | Modos de síntesis                                                                                                                                |
| Efectividad pedagógica            | RCT; revisiones STEM/K-12                | Cuantitativa (pre/post; tiempo; Likert) | Medianas; tamaños de efecto; significancia | Comparativa directa; narrativa interpretativa (Kestin et al., 2025; Chen et al., 2022; A systematic review of AI-driven ITS, 2025)               |
| Transformación docente-estudiante | Marcos institucionales; estudios de aula | Mixta (conceptual + casos)              | Constructos (mediación; agencia)           | Análisis temático; integración con recomendaciones (The quiet transformation, 2025; Creely y Carabott, 2025; U.S. Department of Education, 2023) |



| <b>Dimensión</b>                         | <b>Fuentes</b>                                    | <b>Tipos de evidencia</b>                                | <b>Métricas</b>                                      | <b>Modos de síntesis</b>                                                                                                                                                                                                                                                                  |
|------------------------------------------|---------------------------------------------------|----------------------------------------------------------|------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Desempeño técnico (contenido multimodal) | Estudios transferibles (redes sociales→educación) | Cuantitativa (especificidad; sensibilidad; concordancia) | Especificidad; sensibilidad; acuerdo inter-evaluador | Narrativa de arquitectura + análisis de métricas (Sharp et al., 2025)                                                                                                                                                                                                                     |
| Clasificación de riesgo                  | Estudios educativos                               | ML Cuantitativa (AUC; precisión)                         | AUC/precisión; segmentaciones                        | Interpretación de utilidad y salvaguardas (Vinoth Kumar et al., 2025)                                                                                                                                                                                                                     |
| Contexto iberoamericano                  | Revisión regional; guías                          | Mixta (sistematización + política)                       | Dimensiones (innovación, ética, gobernanza)          | Síntesis por dimensiones; articulación de recomendaciones (Acevedo et al., 2025; EDUTEC, 2024; ILIA 2024, 2024; UNESCO Recommendation on the Ethics, 2024; Regional cooperation, 2024; The future of AI in education, 2023; ANEP, 2024; EDUTEC, 2024; U.S. Department of Education, 2023) |

Los resultados que muestra la Tabla 1 resume las dimensiones abordadas, los tipos de evidencia utilizados, las métricas aplicadas y los modos de síntesis empleados. Esta matriz confirma la triangulación metodológica entre estudios cuantitativos (RCT, revisiones sistemáticas), evidencia conceptual (marcos institucionales, estudios de aula) y análisis técnico (arquitecturas multimodales), permitiendo una lectura

transversal y situada de los filtros educativos basados en IA.

La estrategia de búsqueda multibase, desarrollada entre marzo y junio de 2025, garantizó una cobertura exhaustiva del corpus analizado (Tabla 2).

**Tabla 2.** Mapa de bases de datos utilizadas

| Base de datos  | Alcance                                         | Observaciones                                                                                                  |
|----------------|-------------------------------------------------|----------------------------------------------------------------------------------------------------------------|
| Web of Science | Multidisciplinar (ciencias sociales, educación) | Relevante para artículos de educación y tecnología                                                             |
| Scopus         | Multidisciplinar                                | Cobertura amplia en educación y STEM                                                                           |
| IEEE Xplore    | Tecnología e ingeniería                         | Especializado en IA y sistemas inteligentes                                                                    |
| ERIC           | Educación                                       | Enfoque en educación y tecnología educativa                                                                    |
| PubMed         | Biomedicina y ciencias sociales                 | Aplicable a bienestar y aspectos éticos relacionados (Exploring the effects of AI on student well-being, 2025) |
| PMC            | Acceso abierto                                  | Útil para revisiones K-12 y estudios transferibles (A systematic review of AI-driven ITS, 2025)                |
| MDPI           | Acceso abierto educación                        | Enfoque en aprendizaje adaptativo y e-Learning (Adaptive Learning Using Artificial Intelligence, 2023)         |

La Tabla 2 documenta las bases de datos consultadas, incluyendo Web of Science, Scopus, IEEE Xplore, ERIC, PubMed, PMC y MDPI, cada una con aportes específicos según su enfoque disciplinar. Esta configuración asegura representatividad temática y minimiza sesgos de selección, fortaleciendo la validez metodológica del estudio.

El análisis comparativo requiere examinar los diferentes corpus de evidencia bajo criterios comunes. La siguiente tabla sistematiza las características metodológicas y hallazgos distintivos de cada corpus incluido en el estudio.

**Tabla 3.** Panorama comparado por corpus: tipo de estudio, métricas y contextos

| Corpus                       | Tipo de estudio                | Ámbito y nivel                           | Métricas clave                                       | Resultados distintivos                   |
|------------------------------|--------------------------------|------------------------------------------|------------------------------------------------------|------------------------------------------|
| RCT IA (2025) (Kestin et al) | Ensayo controlado aleatorizado | Superior (física introductoria), EE. UU. | Medianas post-prueba, tiempo, compromiso, motivación | IA > aprendizaje activo en aprendizaje y |

| <b>Corpus</b>                                                        | <b>Tipo de estudio</b>       | <b>Ámbito y nivel</b>             | <b>Métricas clave</b>                              | <b>Resultados distintivos</b>                                                     |
|----------------------------------------------------------------------|------------------------------|-----------------------------------|----------------------------------------------------|-----------------------------------------------------------------------------------|
| al., 2025)                                                           |                              |                                   |                                                    | compromiso; menor tiempo (49 vs 60 min)                                           |
| Revisión STEM (2022) (Chen et al., 2022)                             | Revisión sistemática         | Superior/STEM, internacional      | Taxonomía categorías; distribución de aplicaciones | por Predominio de STI (25%) y predicción (22%); automatización (13%); robots (9%) |
| Revisión general (2024) (Artificial intelligence in education, 2024) | Revisión sistemática         | Superior y general, internacional | Beneficios/limitaciones; diseño responsable        | Potencial con riesgos; aprendizaje mixto; human-in-the-loop; sesgo y privacidad   |
| STI K-12 (2025) (A systematic review of AI-driven ITS, 2025)         | Revisión sistemática         | K-12, internacional               | Compromiso, autorregulación, adaptación            | Efectos positivos con heterogeneidad; necesidad de estandarización                |
| Filtrado multimodal (2025) (Sharp et al., 2025)                      | Estudio técnico y validación | Fuera del aula (redes), EE. UU.   | Especificidad, sensibilidad, concordancia          | Especificidad alta (99.06%); sensibilidad tema-dependiente; verificación humana   |

El análisis comparativo entre corpus de evidencia, sistematizado en la Tabla 3, revela patrones convergentes y divergentes que justifican la elección de una revisión narrativa-analítica. Por ejemplo, el RCT sobre tutores de IA en educación superior (Kestin et al., 2025) muestra mejoras significativas en aprendizaje,

compromiso y eficiencia temporal frente al aprendizaje activo, con tamaños de efecto robustos. La revisión STEM (Chen et al., 2022) identifica predominio de sistemas tutores inteligentes (25%) y aplicaciones de predicción (22%), mientras que la revisión general (Artificial Intelligence in Education, 2024) destaca el potencial de la IA junto con riesgos éticos y técnicos, proponiendo modelos híbridos con mediación humana (human-in-the-loop).

En K-12, los sistemas tutores inteligentes presentan efectos positivos en autorregulación y compromiso, aunque la heterogeneidad metodológica sugiere cautela y necesidad de estandarización (A Systematic Review of AI-driven ITS, 2025). Por su parte, el estudio técnico sobre filtrado multimodal (Sharp et al., 2025) reporta alta especificidad (99.06%) y sensibilidad variable según temática, con baja concordancia interevaluador, lo que refuerza la importancia de la verificación humana en decisiones sensibles.

En conjunto, estos hallazgos confirman la superioridad de enfoques de IA bien diseñados sobre métodos tradicionales en contextos específicos, pero también evidencian divergencias metodológicas que limitan la posibilidad de síntesis cuantitativas homogéneas

Para contextualizar las implicaciones de los hallazgos en marcos internacionales de gobernanza, la siguiente comparativa sintetiza las principales iniciativas y enfoques regionales identificados en el corpus analizado.

**Tabla 4.** Comparativa internacional de iniciativas de IA educativa

| Región                 | Fuente                                          | Foco principal                                                        | Instrumentos de                                               |                                                                     |
|------------------------|-------------------------------------------------|-----------------------------------------------------------------------|---------------------------------------------------------------|---------------------------------------------------------------------|
|                        |                                                 |                                                                       | política                                                      | Resultados/evaluación                                               |
| Europa                 | EDUTECH (2024)<br>(EDUTECH, 2024)               | Gobernanza, alfabetización, algorítmica, uso responsable              | Marcos institucionales; evaluación de impacto; sostenibilidad | Orientaciones prácticas; recomendaciones de despliegue responsable  |
| Estados Unidos         | OET (2023) (U.S. Department of Education, 2023) | Directrices de evaluación y mitigación de riesgos; desarrollo docente | Políticas de uso; rediseño de evaluación; protección de datos | Pautas para docentes y estudiantes; accountability de institucional |
| Asia (Singapur, Japón) | Revisión STEM (2022) (Chen et al., 2022)        | Aprendizaje adaptativo; plataformas inteligentes; automatización      | Estándares técnicos; métricas comparables; escalabilidad      | Ecosistemas con fuerte integración de recomendación y evaluación    |
| Iberoamérica           | Acevedo et al. (2025) (Acevedo                  | Adopción tecnológica; transformación                                  | Pilotos; gobernanza algorítmica;                              | Momento con brechas en capacidades y normativa; necesidad           |

| Región | Fuente      | Foco principal              | Instrumentos de política | Resultados/evaluación |
|--------|-------------|-----------------------------|--------------------------|-----------------------|
|        | ANEP (2024) | pedagógica; ética y calidad | marcos regulatorios      | de evaluación         |

En la tabla 4, se presenta una comparativa internacional que revela modelos diferenciados de gobernanza: Europa enfatiza marcos institucionales y evaluación de impacto; Estados Unidos prioriza directrices operativas y protección de datos; Asia desarrolla ecosistemas técnicos con estándares escalables; e Iberoamérica muestra un impulso emergente con desafíos estructurales. Estos contrastes refuerzan la necesidad de contextualizar la implementación de filtros educativos basados en IA, considerando no solo su efectividad técnica, sino también sus implicaciones éticas, pedagógicas y políticas en cada región.

## DISCUSIÓN

La lectura comparada de resultados en educación superior, STEM y K-12, junto con la evidencia técnica sobre pipelines de moderación de contenido, permite delinear similitudes, diferencias y convergencias metodológicas que trascienden los niveles educativos. El ensayo controlado aleatorizado en educación superior (Kestin et al., 2025) demuestra que, con contenidos equivalentes, un tutor de IA bien diseñado logra mejores resultados de aprendizaje y compromiso, además de reducir el tiempo de dedicación frente a una actividad de aprendizaje activo. Esta eficiencia temporal -mediana de 49 minutos en la condición IA, con mayor proporción de estudiantes por debajo de 60 minutos- sugiere que el andamiaje conversacional y la retroalimentación dirigida optimizan el esfuerzo, maximizando la relación calidad-tiempo.

Las revisiones sistemáticas en STEM y educación superior (Chen et al., 2022; Zawacki-Richter et al., 2019) confirman una distribución de aplicaciones dominada por sistemas tutores inteligentes (25%), predicción del aprendizaje (22%), detección del comportamiento (21%), automatización evaluativa (13%) y robots educativos (9%), con predominio de contextos universitarios y entornos tecnológicos. Este patrón respalda la hipótesis de que los filtros operan como infraestructura transversal: no se trata de herramientas aisladas, sino de capas funcionales que median desde la curaduría de contenidos hasta la personalización de rutas y la evaluación automatizada.

El análisis comparativo entre corpus revela convergencias en la superioridad de la IA frente a métodos tradicionales cuando se diseña con propósito pedagógico explícito. El RCT en física introductoria (Kestin et al., 2025) muestra que la IA supera al aprendizaje activo tanto en logro como en compromiso, con menor tiempo de dedicación. La revisión general de 2024 (Artificial Intelligence in Education, 2024) confirma el potencial de la IA, pero advierte sobre riesgos asociados, recomendando aprendizaje mixto y verificación humana sistemática para abordar sesgo y privacidad. En K-12, la revisión sobre sistemas tutores inteligentes (A Systematic Review of AI-driven ITS, 2025) reporta efectos positivos en compromiso, autorregulación y adaptación, aunque con heterogeneidad metodológica que exige estandarización de métricas. Por su parte, el estudio técnico sobre filtrado multimodal (Sharp et al., 2025) reporta alta especificidad (99.06%) y sensibilidad variable según temática, validando la necesidad de verificación humana en decisiones sensibles.

A partir de estos hallazgos, surgen tres condiciones como determinantes de efectividad: el diseño pedagógico explícito, que incluye andamiaje conversacional y feedback inmediato; el aprendizaje mixto, que preserva la interacción humana; y la incorporación sistemática del human-in-the-loop en procesos de

evaluación y filtrado. La evidencia técnica refuerza que la comprensión contextual de los modelos -mejorada mediante fine-tuning con datos educativos y grafos de conocimiento- incrementa la relevancia de las decisiones algorítmicas (Alia et al., 2024; Sharp et al., 2025). En contraste, las discrepancias en resultados y métricas aparecen cuando la automatización se aplica a tareas de alta ambigüedad, cuando la sensibilidad del filtro varía según el tema, o cuando se mide el impacto sin estandarización de indicadores de equidad, agencia y bienestar estudiantil (Artificial Intelligence in Education, 2024; Exploring the Effects of AI on Student Well-being, 2025; Ali, et al., 2023).

Por otro lado, las experiencias internacionales ofrecen pistas complementarias sobre cómo gobernar, escalar y adaptar los filtros educativos. En Europa, proyectos como ERASMUS y marcos como EDUTECH enfatizan la adopción responsable, la alfabetización algorítmica y la gobernanza institucional, con foco en ética, calidad y sostenibilidad (EDUTECH, 2024). Esta orientación subraya que el despliegue debe acompañarse de evaluación de impacto, transparencia y políticas de uso responsable, incluyendo mitigación ambiental. En Estados Unidos, el informe del Office of Educational Technology propone directrices prácticas para K-12 y sistemas, destacando pautas de uso, evaluación de riesgos, rediseño de evaluación y desarrollo profesional docente (U.S. Department of Education, 2023). La agenda pública se centra en protección de datos, integridad académica y responsabilidad institucional, con métricas y procesos de evaluación institucional claramente definidos.

En Asia, particularmente en Singapur y Japón, la literatura mapea ecosistemas avanzados en aprendizaje adaptativo y plataformas inteligentes, con fuerte integración de recomendaciones y evaluación automatizada. Estos modelos se apoyan en estándares técnicos, métricas comparables y escalabilidad basada en infraestructuras de datos robustas. En contraste, Iberoamérica documenta un momento de adopción en tutores, evaluación automatizada y sistemas de recomendación, aunque enfrenta brechas significativas en infraestructura, formación docente y gobernanza. Las revisiones regionales y nacionales, como las de Acevedo et al. (2025) y ANEP (2024), destacan la necesidad de pilotos evaluados y marcos regulatorios específicos para un escalamiento responsable.

Finalmente, el presente análisis arrastra limitaciones que se deben aclarar. Se observa un sesgo de publicación hacia educación superior y disciplinas STEM, junto con heterogeneidad de métricas, variabilidad en la calidad de los estudios, escasez de seguimientos prolongados en RCTs, concentración geográfica en América del Norte y Europa, y limitada auditoría pública sobre sesgo y privacidad. Estas restricciones no invalidan los hallazgos, pero sí refuerzan la necesidad de futuras investigaciones que amplíen la cobertura temática, geográfica y temporal, incorporando criterios de equidad, agencia y bienestar estudiantil como dimensiones centrales de evaluación.

## **CONCLUSIONES**

La evidencia presentada en el estudio converge en tres conclusiones. En primer lugar, los filtros educativos basados en IA mejoran resultados de aprendizaje y compromiso estudiantil, con eficiencia temporal cuando se diseñan con propósito pedagógico explícito y andamiaje conversacional. El RCT en educación superior muestra medianas de post-prueba superiores con tutor de IA, mayor compromiso y menor tiempo de dedicación, con tamaños de efecto en rangos moderados-altos y significancia robusta. Segundo lugar, la transformación de la relación docente-estudiante hacia co-creación y mediación algorítmica se consolida como modelo pedagógico: el docente asume roles de facilitación y curaduría, mientras la IA optimiza secuenciación, feedback y analítica de riesgo. Tercer lugar, los desafíos técnicos, éticos y de equidad -comprensión contextual, sesgo, privacidad, integridad académica e impacto ambiental- requieren gobernanza sistemática, auditorías periódicas y aprendizaje mixto con verificación humana.

Para docentes, la adopción de filtros de IA demanda diseñar tareas centradas en proceso y creatividad, con prompts que orienten el andamiaje y evaluación formativa que preserve la agencia estudiantil. La mediación algorítmica debe entenderse como soporte a la retroalimentación, no sustituto del juicio pedagógico. Para instituciones, la viabilidad de adopción depende de políticas de datos, infraestructura, formación continua y auditorías de sesgo y privacidad, con reportes abiertos de desempeño. Para desarrolladores, el ajuste fino con datos educativos, grafos de conocimiento y transparencia metodológica son esenciales para precisión, equidad y confianza. Para formuladores de políticas, la creación de marcos de gobernanza algorítmica, lineamientos de uso responsable y métricas estandarizadas de desempeño y equidad permitirá escalamiento responsable.

Para futuras investigaciones se priorizan: RCTs longitudinales en distintos niveles y disciplinas para medir impacto sostenido y equidad; estandarización de métricas (precisión, sensibilidad, especificidad, AUC, retención, satisfacción) con protocolos comparables; auditorías abiertas de sesgo, privacidad y desempeño por grupo demográfico y disciplina; transferencia y validación de pipelines multimodales de cribado en entornos escolares, con evaluación de sensibilidad por temática y carga de revisión humana; estudios de interacción humana y agencia pedagógica en entornos aumentados por IA; evaluación comparativa de filtros en producción (tutores, autograding, recomendación, riesgo) con reportes públicos y trazabilidad de datos (Artificial intelligence in education, 2024; Alia et al., 2024; UNESCO Recommendation on the Ethics, 2024; A systematic review of AI-driven ITS, 2025).

## REFERENCIAS

- A comprehensive AI policy education framework for university teaching and learning. (2023). Educational Technology Journal. <https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-023-00408-3>
- Acevedo, M., Cabezas, N., La Serna, P., y Araujo, S. A. (2025). Desafíos y oportunidades de la inteligencia artificial en la educación superior latinoamericana: una revisión sistemática de la literatura. *Revista Conrado*. [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S2739-00632026000103074](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S2739-00632026000103074)
- AI vs. Human Moderators: A Comparative Evaluation of Multimodal Brand Safety Classification. (2025). arXiv. <https://arxiv.org/html/2508.05527v1>
- AI Governance in Latin America. (2024). Center for Cybersecurity Policy. <https://www.centerforcybersecuritypolicy.org/insights-and-research/ai-governance-in-latin-america>
- Al Faraby, S., Romadhony, A., y Adiwijaya. (2024). Analysis of LLMs for educational question classification and generation. *Computers and Education: Artificial Intelligence*, 7, 100298. <https://www.sciencedirect.com/science/article/pii/S2666920X24001012>
- Ali, O., Murray, P. A., Momin, Y., Dwivedi, Y., y Malik, T. (2023). The effects of artificial intelligence applications in educational settings: Challenges and strategies. *Technological Forecasting and Social Change*, 199, 123076. <https://doi.org/10.1016/j.techfore.2023.123076>
- ANEP. (2024). La inteligencia artificial en la educación. <https://www.anep.edu.uy/sites/default/files/images/2024/noticias/julio/240709/Documento%20IA.pdf>
- Artificial intelligence in education: A systematic literature review. (2024). *Expert Systems with Applications*. <https://www.sciencedirect.com/science/article/pii/S0957417424010339>
- Artificial Intelligence in Education (AIED): Towards More Effective Regulation. (2025). *European*

- Journal of Risk Regulation. <https://www.cambridge.org/core/journals/european-journal-of-risk-regulation/article/artificial-intelligence-in-education-aided-towards-more-effective-regulation/58C6BB8A2E0D43FA3911A063AA2D4DB8>
- A systematic review of AI-driven intelligent tutoring systems (ITS) in K-12 education. (2025). npj Science of Learning, 10, 29. <https://doi.org/10.1038/s41539-025-00320-7>
- Clasificación de las Herramientas de la Inteligencia Artificial en la Educación. (2024). Revista Docentes 2.0. [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S2665-02662024000100031](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S2665-02662024000100031)
- Chen et al. (2022) corresponde al artículo: Chen, L., Chen, P., & Lin, Z. (2022). Artificial intelligence in education: A review. DOI: <https://doi.org/10.1016/j.compedu.2022.104579>
- Course Success Prediction and Early Identification of At-Risk Students using XAI. (2024). Electronics, 13(21), 4157. <https://www.mdpi.com/2079-9292/13/21/4157>
- Creely, E., y Carabott, K. (2025). Teaching and learning with AI: an Integrated AI-Oriented Pedagogical Model. The Australian Educational Researcher. <https://link.springer.com/article/10.1007/s13384-025-00913-6>
- EDUTEC. (2024). Informe EDUTEC sobre Inteligencia Artificial y Educación. <https://edutec.es/wp-content/uploads/2024/11/Edutec-INFORME-IA-MAQUETADO-FINALv2.pdf>
- Exploring the effects of artificial intelligence on student well-being: a mini-review. (2025). PMC. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11830699/>
- Higher Education Act for AI (HEAT-AI): a framework to regulate the use of AI in higher education. (2025). Frontiers in Education. <https://www.frontiersin.org/journals/education/articles/10.3389/feduc.2025.1505370/full>
- ILIA 2024: Evaluating AI Readiness and Progress in Latin America. (2024). CEPAL. <https://www.cepal.org/en/notes/ilia-2024-evaluating-ai-readiness-and-progress-latin-america>
- Irwanto, I. (2025). Research trends on artificial intelligence in K-12 education in Asia: a bibliometric analysis using the Scopus database (1996–2025). Discov Artif Intell, 5, 155. <https://link.springer.com/article/10.1007/s44163-025-00389-4>
- Kestin, G., Miller, K., Klales, A., Milbourne, T., y Ponti, G. (2025). AI tutoring outperforms in-class active learning: an RCT introducing a novel research-based design in an authentic educational setting. Scientific Reports. <https://www.nature.com/articles/s41598-025-97652-6>
- Lin, C.-C., Huang, A. Y. Q., & Lu, O. H. T. (2023). Artificial intelligence in intelligent tutoring systems toward sustainable education: a systematic review. Smart Learning Environments, 10, 41. <https://slejournal.springeropen.com/articles/10.1186/s40561-023-00260-y>
- Myint, P. Y. W., Lo, S. L., & Zhang, Y. (2024). Harnessing the power of AI-instructor collaborative grading approach: Topic-based effective grading for semi open-ended multipart questions. Computers and Education: Artificial Intelligence, 7, 100339. <https://doi.org/10.1016/j.caeai.2024.100339>
- Regional cooperation crucial for AI safety and governance in Latin America. (2024). Brookings. <https://www.brookings.edu/articles/regional-cooperation-crucial-for-ai-safety-and-governance-in-latin-america/>
- Sharp, K., Ouellette, R. R., Singh Rajendra Singh, R., DeVito, E. E., Kamdar, N., de la Noval, A., Murthy, D., y Kong, G. (2025). Generative AI and machine learning methods to screen social media content. PeerJ Computer Science. <https://pmc.ncbi.nlm.nih.gov/articles/PMC11935761/>
- The development of policies on generative artificial intelligence in UK universities. (2025). SAGE Journals. <https://journals.sagepub.com/doi/10.1177/03400352251333796>
- The future of Artificial Intelligence in education in Latin America. (2023). OEI/ProFuturo. <https://oei.int/wp-content/uploads/2023/04/the-future-of-artificial-intelligence-in-education-in->



latin-america-oei-profuturo.pdf

- The quiet transformation of higher education in the AI era. (2025). Open Research Europe. [https://open-research-europe.ec.europa.eu/articles/5-249/v1/pdf?article\\_uuid=add59f3d-1bbf-4b46-a11b-c399df0ec010](https://open-research-europe.ec.europa.eu/articles/5-249/v1/pdf?article_uuid=add59f3d-1bbf-4b46-a11b-c399df0ec010)
- U.S. Department of Education, Office of Educational Technology. (2023). Artificial Intelligence and the Future of Teaching and Learning. <https://www.ed.gov/sites/ed/files/documents/ai-report/ai-report.pdf>
- UNESCO. (2021). Recommendation on the Ethics of Artificial Intelligence. <https://www.unesco.org/en/artificial-intelligence/recommendation-ethics>
- UNESCO. (2024). Recommendation on the Ethics of Artificial Intelligence. <https://www.unesco.org/en/artificial-intelligence/recommendation-ethics>
- UNESCO presents the Artificial Intelligence Readiness Assessment — Mexico. (2023). UNESCO. <https://www.unesco.org/ethics-ai/en/articles/unesco-presents-artificial-intelligence-readiness-assessment-mexico>
- Vinoth, E., Augustian, R., Sundaravadivel, P., y Janaki, P. (2025). Machine learning-driven development of a behaviour-based student classification system (SCS-B) for enhanced educational analytics. *Scientific Reports*. <https://www.nature.com/articles/s41598-025-21332-8>
- Zawacki-Richter, O., Marín, V. I., Bond, M., y Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*. <https://doi.org/10.1186/s41239-019-0171-0>