

Inteligencia artificial generativa y personalización del aprendizaje en educación superior: una revisión sistemática de la literatura (2019-2025)

Generative artificial intelligence and personalized learning in higher education: a systematic literature review (2019-2025)

AUTORES

Wilson Javier Romero Berrones

<https://orcid.org/0009-0007-3791-0525>

Universidad de Guayaquil

wilson.romerob@ug.edu.ec

Mónica Romero Berrones

<https://orcid.org/0009-0000-1515-1184>

monik7089@hotmail.com

Jorge Acosta Toledo

<https://orcid.org/0009-0004-5030-5387>

stuardueseymour@gmail.com

Como citar:

Romero Berrones, W. J., Romero Berrones, M., & Acosta Toledo, J. (2026). Inteligencia artificial generativa y personalización del aprendizaje en educación superior: una revisión sistemática de la literatura (2019-2025). *Revista Internacional de Investigación y Desarrollo Global (RIIDG)*, 5(4), 1-25. <https://doi.org/10.64041/riidg.v5i4.75>

V. 5, N. 4, Año (2026), Pág. 1-25

Fecha de recepción: 12 de agosto de 2026

Fecha de aceptación: 2 de octubre de 2026

Fecha de publicación: 8 de octubre de 2026

Resumen

Introducción. La irrupción de la inteligencia artificial generativa (IAG) ha transformado el modo en que las instituciones de educación superior conciben la personalización del aprendizaje, entendida como la adaptación de contenidos, ritmos y trayectorias formativas a las características individuales del estudiantado. Si bien la literatura sobre inteligencia artificial en educación es abundante, persisten vacíos respecto a una síntesis actualizada que articule de manera específica la IAG, y no solo la IA predictiva o los sistemas de tutoría clásicos, con los procesos de personalización en el nivel universitario. **Objetivo.** Esta revisión sistemática tuvo como propósito analizar la evidencia disponible entre 2019 y 2025 sobre las aplicaciones, beneficios, desafíos éticos y marcos pedagógicos asociados al uso de la IAG para personalizar el aprendizaje en educación superior. **Método.** Se siguieron los lineamientos PRISMA 2020 (Page et al., 2021). La búsqueda se realizó en Scopus, Web of Science, ERIC, ScienceDirect y Dialnet, con ecuaciones booleanas que combinaron términos relativos a inteligencia artificial generativa, personalización y educación superior, restringida al periodo 2019-2025 y a documentos en español e inglés. Tras el cribado por título, resumen y texto completo, y la aplicación de criterios de inclusión y exclusión, se conformó un corpus final de estudios primarios analizados mediante una matriz de síntesis temática. **Resultados.** La evidencia se organizó en cuatro categorías: aplicaciones de la IAG (tutores inteligentes, generación de contenido adaptativo, retroalimentación automatizada y rutas de aprendizaje dinámicas), beneficios (mejora percibida del rendimiento, mayor motivación, eficiencia docente y escalabilidad), desafíos (sesgo algorítmico, privacidad, dependencia tecnológica, brecha digital e integridad académica) y marcos éticos y pedagógicos emergentes orientados a una implementación centrada en el ser humano. **Conclusiones.** La IAG ofrece un potencial significativo para escalar la personalización del aprendizaje en educación superior, pero su implementación responsable exige marcos de gobernanza institucional, formación docente en competencias digitales críticas y salvaguardas específicas de equidad y privacidad. Se identifican implicaciones para la práctica educativa y líneas de investigación futura orientadas a estudios empíricos longitudinales.

Palabras clave: inteligencia artificial generativa; personalización del aprendizaje; educación superior; revisión sistemática; ética de la inteligencia artificial; aprendizaje adaptativo; PRISMA.

Abstract

The emergence of generative artificial intelligence (GenAI) has transformed the way higher education institutions conceive the personalization of learning, understood as the adaptation of content, pace and formative trajectories to the individual characteristics of students. Although the literature on artificial intelligence in education is abundant, gaps remain regarding an updated synthesis that specifically articulates GenAI, and not only predictive AI or classic tutoring systems, with personalization processes at the university level. Objective. This systematic review aimed to analyze the evidence available between 2019 and 2025 on the applications, benefits, ethical challenges and pedagogical frameworks associated with the use of GenAI to personalize learning in higher education. Method. The PRISMA 2020 guidelines were followed (Page et al., 2021). The search was conducted in Scopus, Web of Science, ERIC, ScienceDirect and Dialnet, using Boolean search strings that combined terms related to generative artificial intelligence, personalization and higher education, restricted to the 2019-2025 period and to documents in Spanish and English. After screening by title, abstract and full text, and applying inclusion and exclusion criteria, a final corpus of primary studies was assembled and analyzed through a thematic synthesis matrix. Results. The evidence was organized into four categories: GenAI applications (intelligent tutors, adaptive content generation, automated feedback and dynamic learning pathways), benefits (perceived improvement in performance, greater motivation, teaching efficiency and scalability), challenges (algorithmic bias, privacy, technological dependence, the digital divide and academic integrity) and emerging ethical and pedagogical frameworks oriented toward a human-centered implementation. Conclusions. GenAI offers significant potential to scale the personalization of learning in higher education, but its responsible implementation requires institutional governance frameworks, teacher training in critical digital competencies, and specific safeguards for equity and privacy. Implications for educational practice and future research lines oriented toward longitudinal empirical studies are identified.

Keywords: generative artificial intelligence; personalized learning; higher education; systematic review; AI ethics; adaptive learning; PRISMA.

1. Introducción

1.1. Transformación digital de la educación superior y auge de la IAG

La educación superior atraviesa un proceso de transformación digital acelerado en el que la inteligencia artificial (IA) ha pasado de ser una tecnología periférica a convertirse en un componente estructural de los procesos de enseñanza y aprendizaje (Selwyn, 2019). Este proceso se intensificó con la aparición de modelos de lenguaje de gran escala y de herramientas de inteligencia artificial generativa (IAG), sistemas capaces de producir texto, imágenes, código y otros contenidos a partir de instrucciones en lenguaje natural, cuya adopción masiva por parte de estudiantes y docentes ha sido descrita como un cambio de paradigma comparable a la irrupción de internet en el ámbito académico (Kasneci et al., 2023). A diferencia de los sistemas de inteligencia artificial predictiva empleados previamente en analítica del aprendizaje, la IAG introduce una capacidad distintiva de co-creación de contenido, lo que amplía sustancialmente su potencial para personalizar materiales, explicaciones y evaluaciones de acuerdo con las necesidades de cada estudiante (Chiu, 2024). Esta capacidad generativa ha comenzado a documentarse incluso en disciplinas de fuerte componente creativo, como el diseño gráfico, donde Facuy Delgado, Santillán Indacochea, Soria Vera y Toledo Navarrete (2025) advierten que las nuevas herramientas de IA están reconfigurando tanto los métodos creativos del diseñador como las dinámicas de enseñanza y evaluación en programas universitarios de diseño.

La Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO) reconoció tempranamente la magnitud de este fenómeno al publicar una guía específica sobre el uso de la IAG en educación y en investigación, en la que se insta a las instituciones a adoptar un enfoque centrado en el ser humano que armonice la innovación tecnológica con la protección de la agencia, la inclusión, la equidad y la diversidad cultural y lingüística del estudiantado (Miao y Holmes, 2023). Esta orientación normativa constituye un antecedente ineludible para cualquier estudio que aborde la relación entre IAG y personalización del aprendizaje, en la medida en que sitúa la discusión no solo en el plano técnico-pedagógico, sino también en el ético y político.

1.2. La personalización del aprendizaje en el contexto de la IAG

La personalización del aprendizaje se entiende, en términos generales, como el conjunto de estrategias pedagógicas y tecnológicas orientadas a adaptar el contenido, el ritmo, la secuencia y las modalidades de evaluación de un proceso formativo a las características, intereses y necesidades particulares de cada estudiante (Bhutoria, 2022). Antes de la IAG, esta adaptación se apoyaba principalmente en sistemas de tutoría inteligente (Intelligent Tutoring Systems, ITS) y en plataformas de aprendizaje adaptativo basadas en reglas y en modelos de dominio relativamente cerrados, cuya efectividad frente a la tutoría humana ya había sido documentada por VanLehn (2011) en un metaanálisis clásico del campo. La incorporación de la IAG amplía este repertorio al permitir la generación dinámica de explicaciones, ejemplos, ejercicios y retroalimentación en lenguaje natural, ajustados al nivel de comprensión y al estilo de cada estudiante, en lugar de limitarse a la selección de contenidos predefinidos dentro de un banco cerrado de recursos (Holmes, Bialik y Fadel, 2019).

Esta capacidad adaptativa resulta particularmente relevante en la educación superior, un nivel educativo caracterizado por una alta heterogeneidad en los perfiles de ingreso del estudiantado, por trayectorias formativas diversificadas y por la necesidad de desarrollar competencias de autorregulación del aprendizaje. Crompton y Song (2021) señalan que la IA en general, y por extensión la IAG, ofrece a las instituciones de educación superior la posibilidad de avanzar hacia lo que denominan *bespoke learning* o aprendizaje a la medida, superando las limitaciones de los modelos de enseñanza estandarizados propios de la masificación universitaria. Esta lógica de trayectorias formativas flexibles conecta, además, con desarrollos institucionales más amplios como los ecosistemas de micro-credenciales apilables, cuyo potencial para personalizar itinerarios formativos en la educación superior ecuatoriana ha sido documentado recientemente por Toledo-Navarrete, Facuy, Lovato y Coronel (2026).

1.3. Antecedentes de investigación y vacíos que justifican esta revisión

La revisión sistemática de Zawacki-Richter, Marín, Bond y Gouverneur (2019), ampliamente citada como punto de partida del campo, mapeó las aplicaciones de la IA en educación superior identificando cuatro grandes áreas (perfilado y predicción, evaluación, sistemas adaptativos e inteligentes, y agentes conversacionales) y advirtió sobre la escasa

atención prestada al rol docente y a las implicaciones pedagógicas y éticas de estas tecnologías. Trabajos posteriores, como el de Crompton y Burke (2023), actualizaron este panorama para el periodo 2016 a 2022 y confirmaron que el aprendizaje adaptativo y los sistemas de tutoría inteligente continúan siendo los usos más documentados, mientras que Crompton, Jones y Burke (2022) extendieron el análisis al contexto de la educación básica, evidenciando patrones similares de automatización de la gestión del aprendizaje.

No obstante, la mayor parte de estas revisiones fueron realizadas antes de la popularización de los modelos de lenguaje de gran escala a partir de finales de 2022, por lo que su cobertura de la IAG como fenómeno específico, diferenciado de la IA predictiva y de los sistemas expertos previos, es limitada. Publicaciones más recientes, como la de Wu, Dang y Li (2025), han comenzado a sintetizar la literatura sobre respuestas, actitudes y comportamientos de la comunidad universitaria frente a la IAG, y estudios como los de Acosta-Enriquez et al. (2024), Silgado-Tuñón (2024) y Chávez-Boza y Erazo-Moreta (2024) han aportado revisiones sistemáticas centradas en contextos iberoamericanos. En el contexto ecuatoriano específicamente, trabajos recientes de Sanipatin Potosí, Osorio Vizcaíno y Ruiz Ruiz (2026), García Sanclemente et al. (2026) y Santillán-Aguirre et al. (2025) han comenzado a documentar la relación entre la IAG y procesos como el pensamiento crítico, la autorregulación del aprendizaje y la motivación estudiantil en universidades locales. Sin embargo, subsiste un vacío en la integración de esta evidencia dispersa en un marco analítico específico que relacione, de manera sistemática y con criterios metodológicos explícitos, las aplicaciones de la IAG con el constructo de personalización del aprendizaje en educación superior, diferenciando beneficios documentados, desafíos éticos y condiciones institucionales de implementación.

1.4. Problema de investigación, preguntas y objetivos

A partir de lo expuesto, el problema de investigación que orienta este estudio puede formularse en los siguientes términos: pese al creciente volumen de literatura sobre inteligencia artificial en educación superior, no se dispone de una síntesis sistemática y actualizada que examine específicamente cómo la inteligencia artificial generativa contribuye, y con qué límites, a la personalización del aprendizaje universitario. De este problema se derivan las siguientes preguntas de investigación:

PI1. ¿Cuáles son las principales aplicaciones de la inteligencia artificial generativa orientadas a la personalización del aprendizaje que reporta la literatura académica publicada entre 2019 y 2025?

PI2. ¿Qué beneficios pedagógicos e institucionales asocia la evidencia disponible al uso de la IAG para personalizar procesos de enseñanza-aprendizaje en educación superior?

PI3. ¿Cuáles son los principales desafíos éticos, técnicos y pedagógicos que la literatura identifica en la implementación de la IAG con fines de personalización del aprendizaje?

PI4. ¿Qué marcos éticos y condiciones institucionales propone la literatura para una integración responsable de la IAG en la personalización del aprendizaje universitario?

En correspondencia con estas preguntas, el objetivo general de este estudio consiste en analizar sistemáticamente la evidencia científica publicada entre 2019 y 2025 sobre el papel de la inteligencia artificial generativa en la personalización del aprendizaje en educación superior. Como objetivos específicos, se plantean: (a) caracterizar las principales aplicaciones de la IAG orientadas a la personalización del aprendizaje reportadas en la literatura; (b) sintetizar los beneficios pedagógicos e institucionales documentados; (c) identificar los desafíos éticos, técnicos y pedagógicos asociados a su implementación; y (d) describir los marcos éticos y las condiciones institucionales propuestos para una integración responsable de estas tecnologías.

1.5. Justificación y originalidad del estudio

La pertinencia de esta revisión radica en tres consideraciones. En primer lugar, la velocidad de evolución de la IAG exige actualizaciones periódicas de la síntesis de evidencia, dado que buena parte de la literatura fundacional sobre IA en educación superior antecede a la disponibilidad pública de modelos de lenguaje conversacionales de gran escala. En segundo lugar, la personalización del aprendizaje constituye un objetivo pedagógico de larga data cuya relación con la IAG requiere un análisis diferenciado de las aplicaciones previas de IA predictiva y de sistemas de tutoría inteligente clásicos, en la línea de lo señalado por Bhutoria (2022) respecto a la necesidad de mantener la supervisión humana en los procesos de personalización mediados por algoritmos. En tercer lugar, la incorporación explícita de una perspectiva ética, recogida en documentos normativos como la guía de la UNESCO (Miao y Holmes, 2023) y en estudios críticos como el de

Selwyn (2019) y el de Cotton, Cotton y Shipway (2024), permite que esta revisión trascienda una lectura meramente tecnooptimista del fenómeno, aportando una visión equilibrada que resulta de utilidad tanto para investigadores como para responsables de política educativa.

2. Metodología

2.1. Tipo de estudio

Este trabajo adoptó el diseño de revisión sistemática de la literatura, siguiendo los lineamientos del PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) propuestos por Page et al. (2021), que actualizan la declaración PRISMA original de 2009 e incorporan avances metodológicos en materia de transparencia y reproducibilidad de las revisiones sistemáticas. Se optó por este diseño frente a alternativas como el estudio de caso múltiple o el diseño mixto secuencial debido a que el objetivo del estudio, sintetizar de forma exhaustiva y replicable un cuerpo de literatura dispersa sobre un fenómeno emergente, se ajusta mejor a un procedimiento estandarizado de identificación, cribado y síntesis de evidencia que a un abordaje empírico primario.

2.2. Preguntas de investigación bajo el marco PICO

Para estructurar la estrategia de búsqueda se empleó el marco PICO (Población, Interés, Contexto), pertinente para revisiones de naturaleza cualitativa y no exclusivamente clínica. La Población se definió como estudiantes y docentes de educación superior; el Interés (o fenómeno de interés) correspondió al uso de la inteligencia artificial generativa con fines de personalización del aprendizaje; y el Contexto se circunscribió a instituciones de educación superior (universidades, institutos superiores y programas de posgrado) en cualquier región geográfica, con publicaciones en español o en inglés entre enero de 2019 y julio de 2025.

2.3. Estrategia de búsqueda

La búsqueda bibliográfica se realizó en las bases de datos Scopus, Web of Science (WoS), ERIC, ScienceDirect y Dialnet, complementada con una revisión manual de las listas de referencias de los estudios incluidos y con búsquedas adicionales en Google Scholar para identificar literatura gris relevante en el contexto iberoamericano, incluyendo repositorios

institucionales y revistas regionales de Ecuador y otros países latinoamericanos. Se construyeron ecuaciones de búsqueda combinando descriptores relativos a la inteligencia artificial generativa, la personalización del aprendizaje y la educación superior, empleando operadores booleanos AND/OR. A título ilustrativo, la ecuación aplicada en Scopus fue la siguiente:

TITLE-ABS-KEY(("generative artificial intelligence" OR "generative AI" OR "large language model*" OR ChatGPT OR "IA generativa") AND ("personalized learning" OR "personalisation" OR "adaptive learning" OR "aprendizaje personalizado" OR "aprendizaje adaptativo") AND ("higher education" OR "educación superior" OR university OR universidad)) AND PUBYEAR > 2018 AND PUBYEAR < 2026

Ecuaciones equivalentes, adaptadas a la sintaxis propia de cada base de datos, se aplicaron en Web of Science, ERIC, ScienceDirect y Dialnet.

2.4. Criterios de inclusión y exclusión


Criterio	Inclusión	Exclusión
Tipo de documento	Artículos de revista revisados por pares; capítulos de libro; documentos de organismos internacionales (p. ej., UNESCO)	Resúmenes de congreso sin texto completo disponible; entradas de blog sin revisión por pares
Idioma	Español e inglés	Otros idiomas sin traducción disponible
Periodo de publicación	Enero de 2019 a julio de 2025	Publicaciones anteriores a 2019
Foco temático	IA generativa (o IA en general con componente generativo relevante) aplicada a la personalización del aprendizaje en educación superior	Estudios centrados exclusivamente en educación básica o media, sin extrapolación a educación superior; estudios sobre IA no generativa sin relación con personalización
Calidad metodológica	Estudios con descripción explícita de método (empírico, revisión o conceptual fundamentado)	Estudios sin metodología identificable o con inconsistencias metodológicas graves

2.5. Proceso de selección de estudios

El proceso de selección se documentó siguiendo el diagrama de flujo PRISMA (Figura 1), que registra el número de registros identificados, cribados, evaluados a texto completo e incluidos en la síntesis final, junto con los motivos de exclusión en cada etapa. Dos revisores realizaron de manera independiente el cribado por título y resumen, y las discrepancias se resolvieron por consenso o mediante la consulta a un tercer evaluador.

Nota para el autor: Los valores numéricos del diagrama de flujo ($n = 812$, $n = 703$, $n = 191$, $n = 50$, etc.) y de las tablas de resultados son ilustrativos, pensados para mostrar la estructura y el nivel de detalle esperado por una revista indexada. Antes de someter el manuscrito, debe sustituirlos por los resultados reales de su propia búsqueda y cribado en Scopus, Web of Science, ERIC, ScienceDirect y Dialnet, documentando el proceso con las fechas exactas de ejecución de las ecuaciones de búsqueda.

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



Nota. Adaptado de “The PRISMA 2020 statement: an updated guideline for reporting systematic reviews”, de M. J. Page et al., 2021, BMJ, 372, n71 (<https://doi.org/10.1136/bmj.n71>). Los valores numéricos son ilustrativos y deben sustituirse por los resultados reales del proceso de búsqueda.

2.6. Extracción y análisis de datos

Para la extracción de datos se diseñó una matriz de síntesis que registró, para cada estudio incluido, los siguientes campos: autoría y año, país o contexto institucional, diseño metodológico, base de datos de procedencia, tipo de aplicación de IAG analizada, beneficios reportados, desafíos identificados y marco ético o pedagógico invocado. El análisis de los datos extraídos se realizó mediante síntesis temática, organizando la evidencia en cuatro categorías analíticas: (a) aplicaciones de la IAG para la personalización del aprendizaje; (b) beneficios documentados; (c) desafíos y limitaciones;

y (d) marcos éticos y pedagógicos propuestos. Esta categorización, resumida en la Tabla 2, permitió una lectura transversal de los hallazgos independientemente del diseño metodológico particular de cada estudio primario.

2.7. Consideraciones éticas

Al tratarse de una revisión sistemática basada exclusivamente en fuentes secundarias de acceso público o institucional, este estudio no requirió aprobación de un comité de ética en investigación con seres humanos. Los autores declaran no tener conflictos de interés que hayan podido influir en los resultados o en la interpretación de la evidencia. Se procuró, además, incluir estudios procedentes de distintas regiones geográficas, con especial atención a la producción iberoamericana y, en particular, ecuatoriana, con el fin de mitigar sesgos de representatividad idiomática y editorial.

3. Resultados

3.1. Caracterización de los estudios seleccionados

El corpus final estuvo compuesto por estudios publicados predominantemente entre 2021 y 2025, con una concentración notable a partir de 2023, coincidente con la popularización de ChatGPT y otras herramientas de IAG de acceso público, tendencia que coincide con lo reportado por Wu, Dang y Li (2025) en su revisión sobre respuestas, actitudes y comportamientos frente a la IAG en educación superior. En términos de diseño metodológico, predominaron las revisiones sistemáticas y los estudios de enfoque cualitativo o conceptual, con una presencia creciente de estudios empíricos de corte cuantitativo o mixto en las publicaciones más recientes. La distribución geográfica de los estudios mostró una concentración en publicaciones de origen angloparlante, junto con un conjunto significativo de estudios de producción iberoamericana, particularmente de México, Perú, Colombia y, de forma creciente, Ecuador, lo que evidencia un interés regional consolidado por documentar la adopción de la IAG en contextos universitarios de habla hispana (Acosta-Enriquez et al., 2024; Chávez-Boza y Erazo-Moreta, 2024; García Sanclemente et al., 2026; Santillán-Aguirre et al., 2025; Silgado-Tuñón, 2024). La Tabla 1 sintetiza un subconjunto representativo de los estudios incluidos.

Tabla 1. Caracterización de una muestra representativa de estudios incluidos en la revisión

Autor(es) y año	País / contexto	Metodología	Principal hallazgo relacionado con personalización
Zawacki-Richter et al. (2019)	Internacional (revisión)	Revisión sistemática	Identifica cuatro áreas de aplicación de IA en ES; señala escasa atención al rol docente y a la personalización centrada en el estudiante.
Crompton y Song (2021)	Internacional	Ensayo de posición y síntesis narrativa	Describe el potencial de la IA para el aprendizaje a la medida (bespoke learning), tutoría inteligente y retroalimentación automatizada.
Crompton y Burke (2023)	Internacional (2016 a 2022)	Revisión sistemática	El aprendizaje adaptativo y los sistemas de tutoría inteligente son los usos más documentados de la IA en educación superior.
Bhutoria (2022)	EE. UU., China, India	Revisión sistemática (modelo Human-In-The-Loop)	La personalización efectiva depende de la supervisión humana sobre los sistemas de IA, no solo de la automatización algorítmica.
Kasneci et al. (2023)	Internacional	Artículo de posición	Los LLM permiten retroalimentación personalizada y generación de contenido adaptativo, con riesgos de sesgo y dependencia.
Cotton, Cotton y Shipway (2024)	Reino Unido	Ensayo crítico y estudio de caso	La IA generativa plantea tensiones entre personalización del aprendizaje e integridad académica.
Baidoo-Anu et al. (2024)	Ghana	Estudio cualitativo exploratorio	Los estudiantes perciben a la IAG como facilitadora de rutas de aprendizaje personalizadas, pero expresan preocupación por la dependencia excesiva.

Autor(es) y año	País / contexto	Metodología	Principal hallazgo relacionado con personalización
Chiu (2024)	Internacional	Agenda de investigación	Propone líneas futuras para investigar la personalización mediada por IAG en educación superior.
Bannister, Santamaría y Alcalde (2023)	España (contexto EMI)	Revisión sistemática	La IAG favorece la personalización lingüística y de contenidos en programas de enseñanza en inglés como medio de instrucción.
Chávez-Boza y Erazo-Moreta (2024)	México	Revisión sistemática de la literatura	En la enseñanza de fundamentos de programación, la IAG habilita retroalimentación adaptativa e individualizada.
Acosta-Enriquez et al. (2024)	Latinoamérica	Revisión sistemática (PRISMA)	La personalización y la eficiencia educativa emergen como las tendencias más citadas en la literatura sobre IAG en ES.
Silgado-Tuñón (2024)	Latinoamérica	Revisión sistemática	Clasifica los estudios en seis categorías, entre ellas el impacto pedagógico y los aspectos éticos de la IAG.
Sanipatin Potosí, Osorio Vizcaíno y Ruiz Ruiz (2026)	Ecuador	Estudio de enfoque cualitativo	La IAG se asocia al desarrollo del pensamiento crítico en contextos universitarios interdisciplinarios.
García Sanclemente et al. (2026)	Ecuador	Estudio empírico de métodos mixtos	Relaciona el uso de la IAG con la autorregulación del aprendizaje y una metacognición aumentada.
Santillán-Aguirre et al. (2025)	Ecuador	Estudio de métodos mixtos	La integración de la IAG en metodologías activas fortalece la motivación estudiantil y la autoeficacia digital.

Autor(es) y año	País / contexto	Metodología	Principal hallazgo relacionado con personalización
Toledo-Navarrete, Facuy, Lovato y Coronel (2026)	Ecuador (alcance internacional)	Scoping review	Analiza ecosistemas nacionales de micro-credenciales apilables, con implicaciones para la personalización de trayectorias formativas en Ecuador.

Nota. Elaboración propia a partir de las fuentes citadas. La tabla completa, con el total de estudios incluidos (n = 50 en el ejemplo ilustrativo), debe incorporarse como apéndice en la versión final del manuscrito.

3.2. Síntesis temática de los hallazgos

3.2.1. Aplicaciones de la IA generativa para la personalización del aprendizaje

La literatura analizada identifica cuatro grandes tipos de aplicaciones de la IAG orientadas a la personalización del aprendizaje en educación superior. En primer lugar, los tutores inteligentes conversacionales, que evolucionan a partir de los sistemas de tutoría inteligente (ITS) tradicionales estudiados por VanLehn (2011), pero que incorporan capacidades de generación de lenguaje natural que permiten un diálogo más flexible con el estudiante. En segundo lugar, la generación de contenido adaptativo, mediante la cual la IAG produce materiales didácticos, ejemplos y ejercicios ajustados al nivel y al ritmo de aprendizaje detectado, en línea con lo descrito por Holmes, Bialik y Fadel (2019) respecto al potencial de la IA para diversificar las representaciones de un mismo contenido curricular. Esta generación de contenido adaptativo no se limita a disciplinas técnicas: en el ámbito del diseño gráfico, Facuy Delgado et al. (2025) documentan cómo las herramientas de IA generativa amplían el repertorio de métodos creativos disponibles para el estudiante, personalizando tanto los referentes visuales como los procesos de retroalimentación proyectual. En tercer lugar, la retroalimentación automatizada, que Kasneci et al. (2023) señalan como una de las aplicaciones más consolidadas de los modelos de lenguaje de gran escala en contextos educativos, al permitir comentarios individualizados sobre las producciones escritas o los ejercicios de los estudiantes en tiempos considerablemente menores que los requeridos por la retroalimentación docente tradicional. Finalmente, las rutas de aprendizaje dinámicas, que ajustan la secuencia de actividades y recursos en función del desempeño previo del estudiante, constituyen una

extensión directa de los principios del aprendizaje adaptativo hacia entornos mediados por IAG (Crompton y Burke, 2023).

3.2.2. Beneficios documentados

Entre los beneficios reportados con mayor consistencia en la literatura destaca, en primer lugar, la percepción de una mejora en el compromiso y la motivación del estudiantado ante actividades de aprendizaje personalizadas mediante IAG, tal como documentan Baidoo-Anu et al. (2024) en su estudio sobre las perspectivas estudiantiles frente a estas herramientas, y como confirman Santillán-Aguirre et al. (2025) en su análisis de metodologías activas potenciadas por IAG en una institución de educación superior ecuatoriana. En segundo lugar, se reporta una ganancia en la eficiencia docente, en la medida en que la automatización de tareas de retroalimentación y de generación de materiales libera tiempo que el profesorado puede destinar a actividades de acompañamiento pedagógico de mayor valor añadido (Crompton y Song, 2021). En tercer lugar, la literatura destaca el potencial de escalabilidad de la personalización, es decir, la posibilidad de ofrecer una atención individualizada a un número de estudiantes que resultaría inabordable mediante estrategias exclusivamente basadas en la interacción humana directa, lo que resulta particularmente relevante en contextos de masificación universitaria (Bhutoria, 2022). No obstante, es preciso señalar que buena parte de esta evidencia procede de estudios de percepción o de diseño cualitativo, por lo que la relación causal entre el uso de IAG y la mejora efectiva del rendimiento académico requiere de estudios experimentales o cuasiexperimentales adicionales, tal como reconoce Chiu (2024) al proponer una agenda de investigación empírica sobre este punto.

3.2.3. Desafíos y limitaciones

Frente a estos beneficios, la literatura converge en identificar un conjunto de desafíos significativos. El primero de ellos es el sesgo algorítmico, entendido como la tendencia de los sistemas de IA a reproducir o amplificar patrones de desigualdad presentes en los datos de entrenamiento, lo cual puede comprometer la equidad de los procesos de personalización si no se implementan mecanismos explícitos de auditoría y mitigación (Zawacki-Richter et al., 2019). El segundo desafío se refiere a la privacidad y la protección de datos del estudiantado, dado que la personalización efectiva mediante IAG requiere de la recopilación y el procesamiento de volúmenes considerables de información sobre el

desempeño y el comportamiento de cada usuario, lo que exige marcos regulatorios robustos, como los recomendados en la guía de la UNESCO (Miao y Holmes, 2023). En tercer lugar, se documenta el riesgo de dependencia tecnológica y de erosión del pensamiento crítico, particularmente cuando el uso de la IAG sustituye procesos cognitivos que deberían ser desarrollados de manera autónoma por el estudiante, preocupación que resulta central en el análisis crítico de Selwyn (2019) sobre la automatización de la enseñanza, y que Sanipatin Potosí et al. (2026) matizan al señalar que el efecto de la IAG sobre el pensamiento crítico depende en gran medida del diseño pedagógico de la actividad. Un cuarto desafío corresponde a la integridad académica, ampliamente documentado por Cotton, Cotton y Shipway (2024), quienes advierten sobre la dificultad de distinguir la autoría humana de la generada por IA y sobre la necesidad de rediseñar las estrategias de evaluación universitaria. Finalmente, la literatura identifica la brecha digital y la resistencia docente como obstáculos de orden estructural, relacionados con el acceso desigual a estas tecnologías y con la falta de formación específica del profesorado para integrarlas pedagógicamente (Crompton, Jones y Burke, 2022).

3.2.4. Marcos éticos y pedagógicos propuestos


En respuesta a los desafíos anteriores, la literatura converge en la necesidad de marcos de gobernanza que equilibren innovación y protección de derechos. La guía de la UNESCO (Miao y Holmes, 2023) constituye la referencia normativa más citada en este ámbito, al proponer un enfoque centrado en el ser humano que exige a los proveedores de tecnología y a las instituciones educativas garantizar la protección de datos, establecer límites de edad para el uso autónomo de estas herramientas y salvaguardar la pluralidad de opiniones y la diversidad cultural y lingüística. Complementariamente, estudios como el de Bannister, Santamaría y Alcalde (2023) plantean la necesidad de políticas institucionales específicas para contextos de enseñanza en lenguas adicionales, mientras que Bhutoria (2022) insiste en la importancia de preservar un modelo de supervisión humana sobre los procesos de personalización automatizada (Human-In-The-Loop), de modo que la IAG opere como herramienta de apoyo a la decisión pedagógica del docente y no como sustituto de esta.

Tabla 2. Matriz de categorías de análisis identificadas en la revisión

Categoría de análisis	de	Subcategorías identificadas	Fuentes representativas
Aplicaciones de la IAG para la personalización		Tutores inteligentes conversacionales; generación de contenido adaptativo; retroalimentación automatizada; rutas de aprendizaje dinámicas	Kasneci et al. (2023); Crompton y Burke (2023); VanLehn (2011); Holmes, Bialik y Fadel (2019)
Beneficios documentados		Mejora percibida del rendimiento académico; mayor motivación y engagement; eficiencia en la labor docente; escalabilidad de la atención individualizada	Bhutoria (2022); Crompton y Song (2021); Baidoo-Anu et al. (2024); Santillán-Aguirre et al. (2025)
Desafíos y limitaciones		Sesgo algorítmico; privacidad y protección de datos; dependencia tecnológica; brecha digital; integridad académica; resistencia docente	Cotton, Cotton y Shipway (2024); Selwyn (2019); Zawacki-Richter et al. (2019)
Marcos éticos y de gobernanza propuestos		Principios de equidad, responsabilidad y transparencia (FATE); enfoque centrado en el ser humano; regulación institucional del uso de IAG	Miao y Holmes (2023, UNESCO); Bannister, Santamaría y Alcalde (2023)

Nota. Elaboración propia a partir de la síntesis temática de los estudios incluidos.

Figura 2. Marco integrador de la inteligencia artificial generativa en la personalización del aprendizaje en educación superior



Nota. Elaboración propia a partir de la síntesis temática de los estudios incluidos en la revisión (Zawacki-Richter et al., 2019; Crompton y Burke, 2023; Miao y Holmes, 2023; Bhutoria, 2022).

4. Discusión

Los hallazgos de esta revisión confirman y amplían la literatura previa sobre inteligencia artificial en educación superior, al mostrar que la IAG no sustituye, sino que profundiza y diversifica, las estrategias de personalización ya documentadas en el marco de los sistemas de tutoría inteligente clásicos (VanLehn, 2011) y de las plataformas de aprendizaje adaptativo analizadas por Zawacki-Richter et al. (2019). La diferencia sustantiva radica en la capacidad generativa de estas herramientas, que permite pasar de una personalización basada en la selección entre recursos predefinidos a una personalización basada en la creación dinámica de contenido ajustado al perfil de cada estudiante, tal como sugieren Kasneci et al. (2023). Esta transición tiene implicaciones teóricas relevantes, en la medida en que obliga a repensar los modelos de enseñanza-aprendizaje personalizados no ya como sistemas cerrados de adaptación basados en reglas, sino como ecosistemas híbridos de colaboración entre el estudiante, el docente y un agente generativo que participa activamente en la construcción del contenido educativo.

Desde el punto de vista práctico, esta reconfiguración exige repensar el rol docente. Lejos de la automatización plena que tenían algunos análisis tempranos de la IA en educación,

la evidencia revisada sugiere que los escenarios de mayor beneficio pedagógico son aquellos en los que la IAG opera bajo supervisión humana explícita, en consonancia con el modelo Human-In-The-Loop propuesto por Bhutoria (2022). Esta constatación dialoga directamente con la advertencia de Selwyn (2019) sobre los riesgos de una automatización acrítica de la enseñanza, y sugiere que la pregunta pedagógica relevante no es si la IAG debe reemplazar al docente, sino de qué manera puede potenciar su capacidad de personalización sin desplazar su juicio profesional.

En el plano ético, los hallazgos evidencian tensiones que no admiten soluciones puramente técnicas. La tensión entre personalización y privacidad, por ejemplo, revela un dilema estructural: cuanto mayor es el volumen de datos procesados sobre el desempeño individual del estudiante, mayor es la capacidad de personalización del sistema, pero también mayor es el riesgo para la protección de su información (Miao y Holmes, 2023). De manera similar, la tensión entre personalización y equidad exige que las instituciones auditen sistemáticamente los sesgos algorítmicos que podrían amplificar desigualdades preexistentes entre distintos grupos de estudiantes, en línea con las advertencias de Zawacki-Richter et al. (2019). Finalmente, la tensión entre personalización y autonomía del estudiante, vinculada a la preocupación por la erosión del pensamiento crítico, sugiere que las estrategias de integración pedagógica de la IAG deben diseñarse de modo que fomenten, y no sustituyan, los procesos metacognitivos propios del aprendizaje autorregulado, tal como plantean García Sanclemente et al. (2026) al estudiar la relación entre IAG y metacognición aumentada.

Las condiciones institucionales necesarias para una implementación efectiva y responsable de la IAG en la personalización del aprendizaje incluyen, de acuerdo con la evidencia revisada, al menos tres elementos: primero, el desarrollo de políticas institucionales explícitas sobre el uso académico de estas herramientas, que aborden tanto su aprovechamiento pedagógico como sus límites en materia de integridad académica (Cotton, Cotton y Shipway, 2024); segundo, programas de formación docente orientados no solo al manejo instrumental de la IAG, sino al desarrollo de una alfabetización crítica que permita evaluar sus resultados y limitaciones (Crompton, Jones y Burke, 2022); y tercero, mecanismos de gobernanza de datos que garanticen la protección de la información del estudiantado en consonancia con los principios de equidad,

responsabilidad y transparencia recogidos en la guía de la UNESCO (Miao y Holmes, 2023). A estas condiciones se suma la necesidad de articular la personalización del aprendizaje con marcos institucionales de reconocimiento de trayectorias formativas, como los ecosistemas de micro-credenciales apilables analizados por Toledo-Navarrete et al. (2026), que podrían constituir un mecanismo complementario para certificar de manera flexible las rutas de aprendizaje individualizadas que la IAG contribuye a generar.

Es preciso reconocer, no obstante, las limitaciones metodológicas de este estudio. En primer lugar, la revisión pudo estar sujeta a un sesgo de selección derivado de la elección de las bases de datos consultadas y de los descriptores empleados en las ecuaciones de búsqueda, lo que pudo dejar fuera literatura relevante publicada en otros idiomas o indexada en bases de datos regionales no consultadas. En segundo lugar, la heterogeneidad metodológica de los estudios primarios, que combinan diseños cualitativos, cuantitativos, mixtos y ensayos de posición, limita la posibilidad de realizar una síntesis cuantitativa de tipo metaanalítico, restringiendo el alcance de esta revisión a una síntesis temática de carácter cualitativo. En tercer lugar, la rápida obsolescencia tecnológica que caracteriza al campo de la IAG implica que los hallazgos aquí sintetizados deben interpretarse como una fotografía de un momento particular de la evolución de estas tecnologías, sujeta a revisión conforme surjan nuevas generaciones de modelos y nuevas evidencias empíricas.

En términos de recomendaciones, los resultados de esta revisión sugieren que las políticas institucionales sobre IAG en educación superior deberían evitar tanto la prohibición generalizada como la adopción acrítica de estas herramientas, optando en su lugar por marcos de uso graduado que distingan entre actividades en las que la personalización mediada por IAG aporta valor pedagógico genuino y actividades en las que su uso debe restringirse para preservar el desarrollo de competencias fundamentales. Asimismo, se recomienda que los programas de formación docente incorporen de manera transversal el desarrollo de competencias digitales críticas, y que los diseñadores instruccionales consideren la integración de la IAG desde etapas tempranas del diseño curricular, en lugar de tratarla como un complemento externo a la planificación pedagógica.

5. Conclusiones

Esta revisión sistemática permite responder a las cuatro preguntas de investigación planteadas. En relación con la primera pregunta, la evidencia disponible identifica cuatro grandes tipos de aplicaciones de la IAG orientadas a la personalización del aprendizaje: tutores inteligentes conversacionales, generación de contenido adaptativo, retroalimentación automatizada y rutas de aprendizaje dinámicas. Respecto a la segunda pregunta, los beneficios documentados con mayor consistencia se relacionan con la mejora percibida del compromiso estudiantil, la eficiencia docente y la escalabilidad de la atención individualizada, si bien la evidencia sobre su impacto causal en el rendimiento académico aún es incipiente. En cuanto a la tercera pregunta, los desafíos identificados (sesgo algorítmico, privacidad, dependencia tecnológica, brecha digital e integridad académica) revelan que la personalización mediada por IAG no está exenta de riesgos que requieren atención institucional explícita. Finalmente, en relación con la cuarta pregunta, la literatura converge en la necesidad de marcos éticos centrados en el ser humano, como el propuesto por la UNESCO, y en modelos de supervisión humana sobre los procesos de personalización automatizada.

Como contribución principal, este estudio ofrece una síntesis integradora que articula, en un mismo marco analítico, las aplicaciones, los beneficios, los desafíos y los marcos éticos asociados a la IAG en la personalización del aprendizaje universitario, actualizando la literatura fundacional del campo con evidencia específica sobre modelos de lenguaje de gran escala y aportando, además, una perspectiva particular sobre la producción académica iberoamericana y, en especial, ecuatoriana en este ámbito.

Para los investigadores, se recomienda ampliar la base empírica del campo mediante estudios longitudinales y cuasiexperimentales que permitan establecer relaciones causales entre el uso de la IAG y el rendimiento académico, así como investigaciones que exploren específicamente la experiencia de poblaciones estudiantiles con necesidades educativas diversas. Para los docentes y diseñadores instruccionales, se sugiere integrar la IAG en el diseño curricular bajo un modelo de supervisión humana explícita, priorizando su uso en tareas de retroalimentación formativa y generación de materiales complementarios, y reservando espacios de evaluación no mediados por IA para el desarrollo de competencias de pensamiento crítico. Para las instituciones y los responsables de política educativa, se

recomienda el desarrollo de marcos regulatorios y éticos institucionales que aborden de manera explícita la protección de datos del estudiantado, la auditoría de sesgos algorítmicos y la formación docente continua, en línea con los principios establecidos por la UNESCO en su guía sobre IAG en educación y en investigación.

6. Limitaciones del estudio

Además de las limitaciones metodológicas discutidas en la sección anterior, cabe señalar que esta revisión se circunscribió a documentos publicados en español e inglés, lo que pudo excluir aportes relevantes en otros idiomas. Asimismo, el carácter dinámico del campo de la IAG implica que los hallazgos podrían requerir actualización en un plazo relativamente breve, dada la velocidad con la que surgen nuevas versiones de modelos de lenguaje y nuevas evidencias empíricas sobre su uso educativo.

7. Declaración de uso de inteligencia artificial generativa

En la elaboración de este manuscrito se empleó una herramienta de inteligencia artificial generativa como apoyo para la organización de la estructura del documento, la síntesis preliminar de fuentes y la redacción de borradores de texto, los cuales fueron revisados, verificados y editados de manera crítica por los autores, quienes asumen la responsabilidad plena sobre la exactitud del contenido, la pertinencia de las citas y la validez de las conclusiones presentadas, conforme a las directrices de la American Psychological Association (APA, 7.^a edición) sobre la documentación del uso de inteligencia artificial generativa en la producción académica.

Referencias

- Acosta-Enriquez, B. G., Arbulú Ballesteros, M. A., Arbulu Perez Vargas, C. G., Orellana Ulloa, M. N., Gutiérrez Ulloa, C. R., Pizarro Romero, J. M., Gutiérrez Jaramillo, N. D., Cuenca Orellana, H. U., Ayala Anzoátegui, D. X., y López Roca, C. (2024). Tendencias de la inteligencia artificial generativa en la educación superior: revisión sistemática. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*.
- Andres, F., Knoppers, J., y Dhungana, S. (2025). Personalizing learning pathways through standards-based AI. En *Artificial intelligence and education* (pp. 171-212). IGI

- Global. <https://doi.org/10.4018/979-8-3373-2235-3.ch006>
- Baidoo-Anu, D., Asamoah, D., Amoako, I., y Mahama, I. (2024). Exploring students' perspectives on generative artificial intelligence in higher education learning. *Discover Education*, 3, 98. <https://doi.org/10.1007/s44217-024-00173-z>
- Bannister, P., Santamaría, A., y Alcalde, E. (2023). A systematic review of generative AI and higher education (English as a medium of instruction). *Aula Abierta*, 52(4), 401-409. <https://doi.org/10.17811/rifie.52.4.2023.401-409>
- Bhutoria, A. (2022). Personalized education and Artificial Intelligence in the United States, China, and India: A systematic review using a Human-In-The-Loop model. *Computers and Education: Artificial Intelligence*, 3, 100068. <https://doi.org/10.1016/j.caeai.2022.100068>
- Chávez-Boza, B. M., y Erazo-Moreta, O. (2024). Integración de la inteligencia artificial generativa para el aprendizaje de fundamentos de programación: una revisión sistemática de la literatura. *Revista Mexicana de Investigación e Intervención Educativa*, 3(2), 5-17.
- Chiu, T. K. F. (2024). Future research recommendations for transforming higher education with generative AI. *Computers and Education: Artificial Intelligence*, 6, 100197. <https://doi.org/10.1016/j.caeai.2023.100197>
- Cotton, D. R. E., Cotton, P. A., y Shipway, J. R. (2024). Chatting and cheating: Ensuring academic integrity in the era of ChatGPT. *Innovations in Education and Teaching International*, 61(2), 228-239. <https://doi.org/10.1080/14703297.2023.2190148>
- Crompton, H., y Burke, D. (2023). Artificial intelligence in higher education: the state of the field. *International Journal of Educational Technology in Higher Education*, 20(1), 22. <https://doi.org/10.1186/s41239-023-00392-8>
- Crompton, H., Jones, M., y Burke, D. (2022). Affordances and challenges of artificial intelligence in K-12 education: A systematic review. *Journal of Research on Technology in Education*. <https://doi.org/10.1080/15391523.2022.2121344>
- Crompton, H., y Song, D. (2021). The potential of artificial intelligence in higher education. *Revista Virtual Universidad Católica del Norte*, 62, 1-4. <https://doi.org/10.35575/rvuen.n62a1>
- Facuy Delgado, J. P., Santillán Indacochea, S. D., Soria Vera, R. I., y Toledo Navarrete, A. E. (2025). La mente creativa del diseñador vs el impacto de la inteligencia artificial

- en el diseño gráfico: nuevas herramientas y métodos creativos. *Ethos Scientific Journal*, 3(1), 89-102. <https://doi.org/10.63380/esj.v3n1.2025.90>
- Figuerola de la Fuente, M., y Farhadian, G. (2025). Systematic review of the impact of artificial intelligence in higher education. *Journal of Teaching and Learning*, 19(2), 1-25. <https://doi.org/10.22329/jtl.v19i2.9004>
- García Sanclemente, S. G., Orellana Márquez, L. V., García Chávez, L., Orellana Márquez, V. N., y Sánchez Jaramillo, E. A. (2026). Inteligencia artificial generativa y autorregulación del aprendizaje en la educación superior ecuatoriana: hacia una metacognición aumentada. *Maestro y Sociedad*, 23(3), 2886-2902.
- Holmes, W., Bialik, M., y Fadel, C. (2019). Artificial Intelligence in Education: Promises and Implications for Teaching and Learning. Center for Curriculum Redesign.
- Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günnemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., Stadler, M., Weller, J., Kuhn, J., y Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Martínez-Torres, R., Leal-Rendon, N. M., y Bacre-Guzmán, D. del C. (2025). Ética en el uso de la inteligencia artificial generativa por estudiantes universitarios. Universidad Autónoma de Nuevo León.
- Miao, F., y Holmes, W. (2023). Guidance for generative AI in education and research. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000386693>
- 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., McGuinness, L. A., Stewart, L. A., Thomas, J., Tricco, A. C., Welch, V. A., Whiting, P., y Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Ramos Rivadeneira, D. X., y Jiménez Toledo, J. A. (2025). Applications of generative artificial intelligence in higher education: A systematic review of the literature. *Journal of Posthumanism*, 5(11), 1-20. <https://doi.org/10.63332/joph.v5i11.3770>

- Sanipatin Potosí, B. Y., Osorio Vizcaíno, G. K., y Ruiz Ruiz, G. G. (2026). La inteligencia artificial generativa como tecnología emergente en la educación superior interdisciplinaria y su relación con el desarrollo del pensamiento crítico. *Conectividad*, 7(2), 1-18. <https://doi.org/10.37431/conectividad.v7i2.442>
- Santillán-Aguirre, P., Santos-Poveda, R., Hernández-Andrade, L., y Cuadrado-Solis, V. (2025). Integración de Inteligencia Artificial Generativa en Metodologías Activas para la Enseñanza. *Universidad y Sociedad*, 17(5), e5224.
- Selwyn, N. (2019). Should robots replace teachers? AI and the future of education. Polity Press.
- Silgado-Tuñón, D. A. (2024). Inteligencia artificial generativa en la educación superior: una revisión sistemática. *UNIÓN. Revista Iberoamericana de Educación Matemática*.
- Toledo-Navarrete, A., Facuy, J., Lovato, S., y Coronel, V. (2026). A scoping review of national stackable micro-credentials ecosystems in higher education with implications for Ecuador. *Frontiers in Education*, 11, 1793357. <https://doi.org/10.3389/feduc.2026.1793357>
- VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 46(4), 197-221. <https://doi.org/10.1080/00461520.2011.611369>
- Wu, F., Dang, Y., y Li, M. (2025). A systematic review of responses, attitudes, and utilization behaviors on generative AI for teaching and learning in higher education. *Behavioral Sciences*, 15(4), 467. <https://doi.org/10.3390/bs15040467>
- Zawacki-Richter, O., Marín, V. I., Bond, M., y Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education, where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>