

Inteligencia artificial en educación superior: personalización del aprendizaje y autonomía estudiantil. Revisión sistemática de la literatura

Artificial Intelligence in Higher Education: Personalized Learning and Student Autonomy. A Systematic Literature Review

John Steven Segarra Briones

jsegarrab2@unemi.edu.ec

Maestría en Educación, Escuela de Educación, Facultad de Posgrados, Universidad Estatal de Milagro, Milagro, Ecuador

ORCID: <https://orcid.org/0009-0005-3766-9714>

Resumen

Este artículo presenta una revisión sistemática de la literatura sobre la Inteligencia Artificial (IA) en la educación superior, centrada en la personalización del aprendizaje y el fomento de la autonomía estudiantil. La búsqueda se realizó en 2026, considerando publicaciones hasta marzo de 2026. Los estudios analizados muestran que la IA puede adaptar experiencias educativas a las necesidades individuales de los estudiantes, apoyar la autorregulación y la toma de decisiones autónoma, y ofrecer retroalimentación contextualizada para optimizar trayectorias de aprendizaje. Sin embargo, se observa que los beneficios dependen de la coherencia pedagógica, el diseño ético de los algoritmos y la integración de enfoques metacognitivos, así como de condiciones organizativas y contextuales. La revisión destaca brechas en la aplicación práctica y evidencia limitaciones sobre los impactos sostenidos, lo que subraya la necesidad de futuras investigaciones que consideren dimensiones pedagógicas, éticas y socioculturales para guiar implementaciones efectivas de IA en educación superior. Estos hallazgos ofrecen un marco para diseñar sistemas educativos personalizados y promover la autonomía del estudiante de manera ética y contextualizada.

Palabras clave: inteligencia artificial, educación personalizada, autonomía estudiantil, innovación educativa, aprendizaje adaptativo, ética digital.

Abstract

This article presents a systematic literature review on the use of Artificial Intelligence (AI) in higher education, focusing on personalized learning and the promotion of student autonomy. The literature search was conducted in 2026 and included publications available up to March 2026. The studies reviewed indicate that AI can tailor educational experiences to students' individual needs, support self-regulated learning and autonomous decision-making, and provide contextualized feedback to optimize learning pathways. However, the findings also reveal that these benefits depend on pedagogical coherence, the ethical design of AI algorithms, the integration of metacognitive approaches, and appropriate organizational and contextual conditions. The review identifies gaps in practical implementation and highlights limited evidence regarding the long-term impacts of AI, underscoring the need for future research that incorporates pedagogical, ethical, and sociocultural dimensions to guide effective AI implementation in higher education. These findings provide a framework for designing personalized educational systems and fostering student autonomy in an ethical and context-sensitive manner.

Keywords: artificial intelligence, personalized learning, student autonomy, educational innovation, adaptive learning, digital ethics.

1. Introducción

La educación superior atraviesa un proceso de transformación profunda debido a la irrupción constante de nuevas tecnologías que modifican las posibilidades en los procesos de enseñanza y aprendizaje. Entre estas tecnologías, la Inteligencia Artificial (IA) se destaca por su capacidad de transformar significativamente los entornos universitarios. Este fenómeno se ha visto acelerado por la rápida digitalización tras la pandemia global, el acceso masivo a dispositivos conectados, el incremento en la generación de datos educativos y el desarrollo de algoritmos más sofisticados (Isea Arguelles et al., 2024).

En Latinoamérica, y particularmente en Ecuador, la adopción de estas tecnologías en la educación superior avanza de manera diferenciada, condicionada por problemas estructurales específicos como la brecha digital, la formación docente y las limitaciones curriculares, evidenciadas en estudios regionales recientes (Quinde Rosales et al., 2024). La capacidad de las instituciones universitarias para implementar tecnologías de IA depende no solo de los recursos disponibles, sino también de factores culturales, económicos y políticos. Por ello, resulta esencial un análisis crítico que considere los efectos transformadores y las limitaciones de la IA en contextos de educación superior.

La promesa de personalización que ofrecen las herramientas de IA representa una posible respuesta a uno de los desafíos más persistentes en educación superior: atender de manera efectiva la diversidad cognitiva, cultural y contextual de los estudiantes universitarios (Villamar Ponce et al., 2024). Los sistemas de Análisis de Aprendizaje, Tutores Inteligentes y los marcos de Minería de Datos Educativos (EDM) permiten adaptar dinámicamente el contenido, la secuenciación, el ritmo e incluso las estrategias pedagógicas a las preferencias y características únicas de cada estudiante, ofreciendo experiencias formativas más efectivas y significativas que los enfoques estándar tradicionales.

Simultáneamente, el desarrollo de la autonomía estudiantil surge como una competencia esencial en sociedades caracterizadas por el cambio constante y la rápida obsolescencia del conocimiento. Las tecnologías impulsadas por IA facilitan la autorregulación mediante andamiajes adaptativos que apoyan la planificación, el monitoreo y la evaluación del aprendizaje, aunque la literatura reciente muestra tensiones entre la personalización algorítmica y la autonomía auténtica, lo que indica la necesidad de diseños intencionales que equilibren el apoyo tecnológico y la transferencia progresiva del control al estudiante universitario (Aguirre-Aguilar et al., 2024).

La integración de estos sistemas en entornos de educación superior plantea profundas implicaciones pedagógicas, organizativas y éticas, transformando el rol docente hacia funciones más complejas como el diseño de experiencias adaptativas, la interpretación contextualizada de análisis y la mediación entre algoritmos y necesidades humanas (Alfaro Salas y Díaz Porras, 2024). Al mismo tiempo, emergen desafíos éticos relacionados con la privacidad de los datos educativos, sesgo algorítmico, inequidad digital y la salvaguarda de dimensiones irreduciblemente humanas del proceso formativo.

El objetivo principal de esta investigación es describir la evidencia reportada sobre la IA en la personalización del aprendizaje y el desarrollo de la autonomía estudiantil en educación superior. Para lograrlo, se plantea un análisis crítico mediante revisión sistemática de la literatura, considerando criterios de análisis y síntesis que incluyen categorías, variables de extracción y enfoque integral de evaluación de resultados.

Los objetivos específicos y sus preguntas de investigación son los siguientes:

Primero, se busca identificar las tipologías de tecnologías de IA utilizadas en educación superior, con la pregunta: ¿Qué tipos de herramientas y sistemas de IA se emplean en la educación universitaria para personalizar el aprendizaje y fomentar la autonomía?

Segundo, se pretende analizar los resultados reportados sobre la personalización del aprendizaje mediante IA, respondiendo a la pregunta: ¿Cómo influye la implementación de IA en la personalización de experiencias educativas en estudiantes universitarios?

Tercero, se examinan los hallazgos relacionados con el desarrollo de la autonomía estudiantil facilitada por IA, con la pregunta: ¿Qué evidencia existe sobre la promoción de la autonomía y autorregulación de los estudiantes universitarios mediante tecnologías de IA?

Finalmente, se busca determinar los factores críticos y limitaciones que condicionan la efectividad de estas tecnologías en contextos universitarios, respondiendo a la pregunta: ¿Qué condicionantes y barreras identificadas en la literatura afectan la implementación efectiva de la IA en educación superior y su capacidad para potenciar la autonomía y personalización del aprendizaje?

2. Metodología

Este estudio realizó una revisión documental sistemática siguiendo las directrices de la declaración PRISMA, incluyendo su diagrama de flujo y lista de verificación. La revisión se enfocó en identificar investigaciones relacionadas con inteligencia artificial, aprendizaje personalizado y autonomía estudiantil.

La búsqueda de literatura se realizó entre enero y marzo de 2026 en la base de datos de Scopus, para garantizar la inclusión de investigaciones con visibilidad internacional y estudios centrados en contextos de América Latina.

Se definió una estrategia de búsqueda avanzada basada en tres ejes conceptuales interconectados: inteligencia artificial, educación personalizada y autonomía estudiantil. Los términos utilizados se seleccionaron del Tesoro de la UNESCO y de la literatura especializada. Se emplearon descriptores y sinónimos en español e inglés, combinados con operadores booleanos AND y OR, aplicados en los campos de título, resumen y palabras clave (Ver tabla 1).

Tabla 1. Ecuación de búsqueda avanzada (Scopus)

Idioma	Ecuación de búsqueda	Campos aplicados	Filtros
Español	("inteligencia artificial" OR "IA en educación") AND ("educación personalizada" OR "aprendizaje adaptativo") AND ("autonomía estudiantil" OR "metacognición")	Título, resumen, palabras clave	Artículos publicados hasta 2026, artículos de investigación, áreas temáticas: Educación, Ciencias de la Computación
Inglés	("artificial intelligence" OR "AI in education") AND ("personalized education" OR "adaptive learning") AND ("student autonomy" OR "metacognition")	Título, resumen, palabras clave	Idem

Tras la búsqueda inicial, los artículos fueron filtrados aplicando criterios de inclusión y exclusión:

1. Publicación hasta el año 2026.
2. Idioma: español e inglés
3. Trabajos empíricos, revisiones sistemáticas, revisiones críticas, estudios bibliométricos, marcos conceptuales o documentos académicos que aporten evidencia, análisis o criterios relevantes sobre inteligencia artificial, personalización del aprendizaje, autonomía estudiantil o docencia universitaria en educación superior.
4. Exclusión de artículos duplicados o repetidos entre bases de datos.

Se identificaron 47 registros en la base de datos Scopus y no se incorporaron registros adicionales provenientes de otras fuentes. Posteriormente, se eliminaron 0 registros duplicados y se excluyeron 18 registros mediante filtros previos relacionados con el idioma y/o el año de publicación, quedando 29 registros para el proceso de cribado. Estos 29 registros fueron revisados por título, resumen y palabras clave, etapa en la cual se excluyeron 14 documentos por no cumplir con los criterios de inclusión. Finalmente, se evaluaron 15 artículos de texto completo para determinar su elegibilidad, sin exclusiones adicionales, por lo que se incluyeron 15 estudios en la síntesis narrativa, como se ilustra en el diagrama de flujo y las cuatro fases de la revisión sistemática mostradas en la Figura 1.

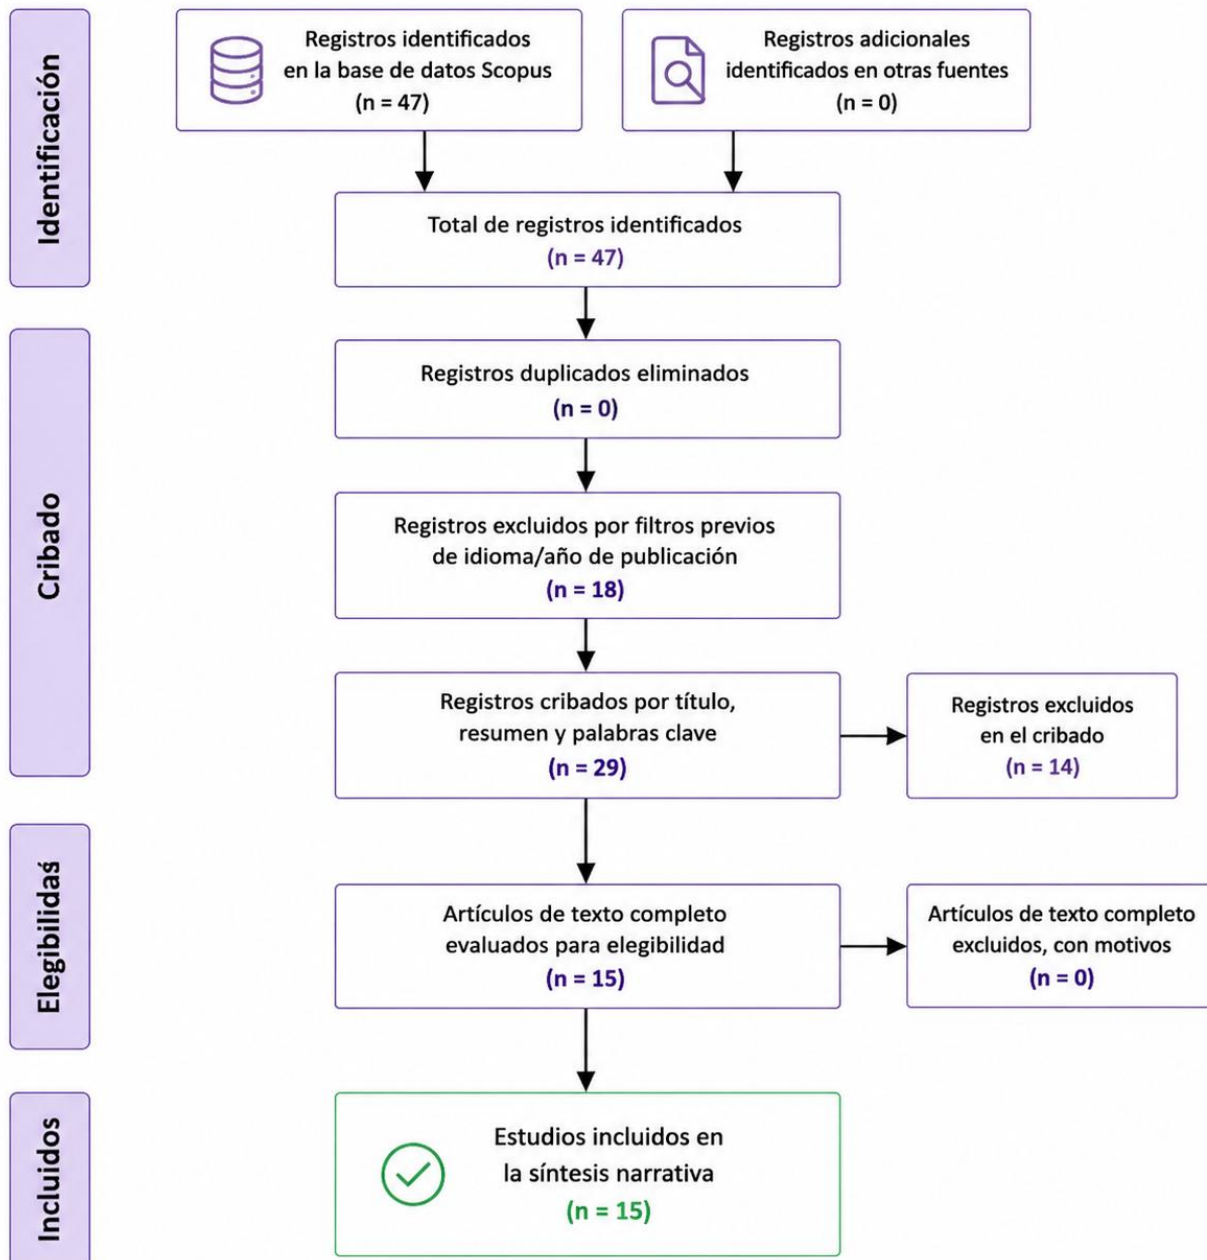


Figura 1. Diagrama de flujo de la revisión sistemática

La Figura 1 resume el proceso de identificación, cribado, elegibilidad e inclusión de los estudios. Se identificaron 47 registros en la base de datos Scopus y no se incorporaron registros adicionales de otras fuentes. Luego de aplicar filtros de idioma y año de publicación, se excluyeron 18 registros, quedando 29 documentos para el proceso de cribado por título, resumen y palabras clave. En esta etapa se excluyeron 14 documentos por no cumplir con los criterios de inclusión. Finalmente, se evaluaron 15 artículos a texto completo, sin exclusiones adicionales, por lo que se incluyeron 15 estudios en la síntesis narrativa.

Con el fin de fortalecer la validez metodológica del estudio, se incorporó un proceso de evaluación de calidad de los estudios incluidos, utilizando instrumentos estandarizados según el tipo de

investigación. Para estudios cualitativos y revisiones se aplicó el Critical Appraisal Skills Programme (CASP), mientras que para estudios cuantitativos y cuasi-experimentales se utilizó la guía del Joanna Briggs Institute (JBI). La evaluación consideró criterios como claridad de objetivos, coherencia metodológica, validez del diseño, calidad de los datos y consistencia de los resultados, clasificando cada estudio en niveles de calidad alta, media o baja.

3. Resultados

Tabla 2. Principales aspectos de los artículos analizados

Nº	Autor/año	Tipo de estudio	Muestra / escenario	Tecnología IA	Variable de personalización / autonomía	Hallazgo clave
1	Essel et al. (2022)	Experimental	Universitarios (Ghana)	Chatbot educativo	Retroalimentación personalizada	Mejora el engagement
2	Bearman et al. (2022)	Revisión crítica	Literatura internacional	IA en educación	Autonomía docente	Discursos inconsistentes
3	Crompton y Burke (2023)	Revisión sistemática	50+ estudios	IA educativa	Aprendizaje adaptativo	Apoyo pedagógico efectivo
4	Chan (2023)	Marco conceptual	Asia	Políticas de IA	Autonomía institucional	Modelo de integración
5	Chan y Hu (2023)	Encuesta	200 estudiantes	IA generativa	Personalización	Utilidad percibida alta
6	Barrett y Pack (2023)	Cualitativo	60 participantes	ChatGPT	Producción académica	Necesidad de regulación
7	Bond et al. (2024)	Meta-sistemática	100+ estudios	IA educativa	Personalización docente	Requiere mayor rigor
8	Delcker et al. (2024)	Cuasi-experimental	120 estudiantes	IA educativa	Autonomía de aprendizaje	Mejora uso de IA
9	Yusuf et al. (2024)	Conceptual	Global	IA generativa	Integridad académica	Tensiones éticas
10	Xia et al. (2024)	Scoping review	Educación superior	IA generativa	Evaluación adaptativa	Cambios en evaluación
11	Mah y Groß (2024)	Encuesta	150 docentes	IA general	Autonomía docente	Perfiles diferenciados
12	Belkina et al. (2025)	Revisión de casos	25 casos	IA generativa	Personalización	Mayor participación

13	Jin et al. (2025)	Revisión institucional	Global	IA generativa	Autonomía institucional	Buenas prácticas
14	Sun et al. (2026)	Marco teórico	Docentes	IA generativa	Competencias docentes	Marco formativo
15	Dai et al. (2026)	Bibliométrico	2022–2025	IA generativa	Tendencias investigación	Áreas emergentes

Los resultados se organizaron en cuatro categorías vinculadas con los objetivos específicos: tipologías de tecnologías de IA en educación superior, personalización del aprendizaje, autonomía estudiantil y factores críticos de implementación. La síntesis se desarrolló de manera narrativa, considerando la calidad metodológica, el tipo de estudio y la pertinencia de los hallazgos reportados en los 15 artículos incluidos. De manera complementaria, se utilizaron referencias teóricas y metodológicas para contextualizar conceptos como autonomía, metacognición, carga cognitiva y autorregulación.

Tipologías de tecnologías de IA identificadas

Los estudios incluidos evidencian una diversidad de tecnologías de inteligencia artificial aplicadas en la educación superior. Entre las principales tipologías identificadas se encuentran los chatbots educativos y asistentes virtuales, utilizados para apoyar procesos de tutoría, retroalimentación y acompañamiento académico; las herramientas de inteligencia artificial generativa, especialmente vinculadas con la producción académica, la evaluación, la escritura y el apoyo a tareas complejas; los sistemas de aprendizaje adaptativo, orientados a ajustar contenidos, actividades y rutas de aprendizaje según las necesidades del estudiante; y los sistemas de evaluación automatizada o asistida por IA, empleados para diversificar los mecanismos de retroalimentación y seguimiento. También se identifican estudios centrados en marcos de política institucional, competencias docentes y modelos de adopción universitaria, lo que evidencia que la IA no se limita al uso instrumental de plataformas, sino que también implica decisiones pedagógicas, éticas, organizativas y de gobernanza en la educación superior.

Personalización del aprendizaje

En relación con la personalización del aprendizaje, los estudios analizados señalan que la IA puede favorecer la adaptación de experiencias educativas a partir de las características, necesidades y desempeños de los estudiantes. Los hallazgos muestran que las tecnologías basadas en IA permiten ofrecer retroalimentación diferenciada, recomendaciones de aprendizaje, apoyo en la resolución de tareas académicas y ajustes en los procesos de evaluación. Esta personalización se observa especialmente en herramientas de IA generativa, sistemas adaptativos, chatbots y plataformas de apoyo al aprendizaje. No obstante, los resultados también indican que la personalización no depende únicamente de la disponibilidad tecnológica, sino de la coherencia pedagógica con la que se integre en el proceso formativo. Por tanto, la IA puede contribuir a experiencias de aprendizaje más flexibles y contextualizadas, siempre que su implementación responda a objetivos educativos claros y no se reduzca a una automatización superficial de contenidos o respuestas.

Autonomía estudiantil y docente

Respecto a la autonomía, la evidencia revisada muestra que la IA puede apoyar procesos de autorregulación, toma de decisiones académicas y gestión autónoma del aprendizaje. Los estudios reportan que los estudiantes pueden beneficiarse de herramientas que ofrecen

orientación personalizada, retroalimentación inmediata, apoyo en la planificación de tareas y recursos para monitorear su propio progreso. Sin embargo, también se advierte que la autonomía no se fortalece de manera automática por el uso de IA; requiere que los sistemas sean transparentes, que permitan opciones reales de decisión y que promuevan el desarrollo de habilidades metacognitivas. En el caso de los docentes, los estudios destacan la importancia de la autonomía profesional para decidir cómo, cuándo y con qué propósito integrar la IA en la enseñanza universitaria. De este modo, la autonomía estudiantil y docente aparece vinculada al uso crítico, ético y pedagógicamente mediado de la inteligencia artificial.

Factores críticos de implementación

Los estudios incluidos identifican diversos factores que condicionan la implementación efectiva de la IA en educación superior. Entre los factores favorables se encuentran la existencia de políticas institucionales claras, la formación docente, la alfabetización en IA, la disponibilidad de infraestructura tecnológica y la articulación de las herramientas con objetivos pedagógicos definidos. Entre las principales limitaciones se destacan la falta de lineamientos éticos, los riesgos de sesgo algorítmico, la privacidad de los datos, la dependencia tecnológica, la desigualdad en el acceso y la escasa evidencia sobre impactos sostenidos a largo plazo. Asimismo, los estudios señalan que la implementación de IA requiere una mirada contextual, especialmente en instituciones de educación superior con distintas capacidades tecnológicas, culturales y organizativas. En consecuencia, la efectividad de la IA no debe asumirse como resultado directo de la tecnología, sino como producto de una integración planificada, ética y pedagógicamente fundamentada.

Discusión temática de los hallazgos

Inteligencia Artificial en contextos educativos

La incorporación de la Inteligencia Artificial en el ámbito educativo se refiere al uso de infraestructuras y tecnologías que poseen funciones como la percepción, aprendizaje, razonamiento y toma de decisiones dentro de los procesos educativos (Panqueban y Huincahue, 2024). A diferencia de la tecnología digital convencional, los sistemas de IA se destacan por sus herramientas potenciadas por IA por su procesamiento adaptivo, desempeño, alimentado por datos y actualización automática de respuestas.

La IA aplicada en el ámbito educativo se materializa, principalmente, en cinco tipos de aplicaciones: tutorías inteligentes, clases autodirigidas, evaluadores automatizados, asistentes virtuales y sistemas de análisis predictivo (Arias-Chávez et al., 2024). Como propósito de ofrecer experiencias educativas moldeables y personalizadas, estas aplicaciones hacen uso de aprendizaje de máquinas, procesamiento de lenguaje natural, análisis de sentimientos, sistemas expertos, redes neuronales y algoritmos bayesianos.

Bustamante Bula y Camacho Bonilla (2024) señalan que esta idea de IA aplicada a la educación ha evolucionado de enfoques estrictamente instrumentales a interpretaciones holísticas que lo conceptualizan como parte de un ecosistema sociotécnico, donde la tecnología educativa no debe centrarse en la sofisticación de la infraestructura, sino en su capacidad de potenciar interacciones pedagógicas profundas.

Aprendizaje Personalizado

La personalización en el aprendizaje es un enfoque que trata sobre la singularidad de cada uno de los estudiantes y forma los procesos para capacitarlos en consecuencia. Esto se diferencia de otros esquemas conceptuales basados en simplificaciones, que, en su nomenclatura, no se

limita al ritmo de progreso, sino a muchos otros factores, como contenidos, metodologías, secuenciación, evaluación y retroalimentación, entre otros (Villamar Ponce et al., 2024).

En la actualidad, impulsada por la IA, la personalización ofrece características más marcadas, como: en los casos donde se obtiene de la educación, se fundamenta en datos; su funcionamiento es constante y flexible, no limitado a intervalos preestablecidos; relaciona variables cognitivas, metacognitivas y no cognitivas; y tiene propósitos de predicción, ajustándose proactivamente a lo que requiera el estudiante (Galarza Ramírez et al., 2024).

Una personalización efectiva mantiene el equilibrio entre marcos algorítmicos y la elección del estudiante. No es una estandarización disfrazada ni una hiperpersonalización que aisle al individuo (Castro et al., 2024). Desde este prisma, la optimización de rutas se ha considerado el aprendizaje flexible autodirigido y el empoderamiento del aprendiz, el que ha de ser capaz de co-diseñar su proceso apoyado en herramientas inteligentes.

Autonomía del Estudiante

La autonomía del estudiante se define como la capacidad del educando para autogestionar sus actividades de aprendizaje, tomando decisiones sobre qué, cómo, cuándo y por qué aprender (Rodríguez Ramírez et al., 2024). Esta capacidad va más allá de la independencia. No se trata solo de independencia; incluye metacognición, autorregulación, motivación intrínseca y agencia epistémica.

Con respecto a los entornos potenciado por IA, la autonomía adquiere matices particulares. A medida que la mayoría de los sistemas tradicionales de Instrucción Asistida por Computadora (CAI) limitaban las elecciones del estudiante dentro de caminos estructurados, los sistemas avanzados de IA buscan expandir progresivamente el espacio de decisión del aprendiz dentro de un marco estructurado que se retira lentamente a medida que se desarrollan competencias (Aguirre-Aguilar et al., 2024).

Esta forma de autonomía en contextos de aprendizaje con IA sugiere una paradoja peculiar: el aprendiz gana libertad de elección precisamente dentro de la interdependencia estructurada por sistemas inteligentes diseñados para monitorear y facilitar su crecimiento. Resolver efectivamente esta tensión requiere sistemas adaptativos sofisticados que no solo personalicen el material, sino que también fomenten la reflexión metacognitiva, la transparencia decisional y disminuyan gradualmente el control sobre el aprendiz (Alfaro Salas y Díaz Porras, 2024).

Evolución Histórica de la IA en la Educación

El desarrollo de la inteligencia artificial en el ámbito educativo puede comprenderse a través de cuatro etapas evolutivas. La primera etapa (1970–1990) estuvo caracterizada por el desarrollo de sistemas tutoriales inteligentes basados en reglas y modelos conductistas de aprendizaje, con estructuras altamente rígidas, limitada adaptabilidad y escasa capacidad de personalización. Estos sistemas se centraban principalmente en la instrucción programada y en la automatización de respuestas educativas.

La segunda etapa (1990–2010) incorporó avances en algoritmos de aprendizaje automático y en la representación del conocimiento, lo que permitió un incremento progresivo en la capacidad de adaptación de los sistemas educativos. Sin embargo, la personalización del aprendizaje aún era limitada y dependía de modelos estadísticos básicos y reglas predefinidas de interacción.

La tercera etapa (2010–2020) se consolidó con el desarrollo del aprendizaje profundo, la analítica del aprendizaje (learning analytics) y el procesamiento del lenguaje natural, lo que permitió una mayor capacidad de análisis de datos educativos. En esta fase se fortalecieron los sistemas de

personalización del aprendizaje y se amplió la interacción entre estudiantes y plataformas digitales educativas.

La cuarta etapa (2020–actualidad) se caracteriza por la consolidación de modelos de inteligencia artificial de propósito general, sistemas multimodales y modelos generativos basados en grandes volúmenes de datos. Estos avances han permitido la integración de asistentes conversacionales y sistemas adaptativos avanzados en contextos educativos, ampliando las posibilidades de personalización del aprendizaje y apoyo a la autonomía estudiantil (Arias-Chávez et al., 2024).

Estos desarrollos tecnológicos han estado acompañados por una evolución en los enfoques pedagógicos, transitando desde modelos conductistas hacia enfoques constructivistas, socioconstructivistas y conectivistas, en los cuales el estudiante es considerado un sujeto activo en la construcción del conocimiento, en interacción con su entorno y con herramientas digitales.

En este contexto, diversas investigaciones han demostrado que los sistemas de inteligencia artificial pueden contribuir a procesos de aprendizaje asincrónico y personalizado, siempre que su uso sea mediado pedagógicamente. Desde la perspectiva de la teoría de la carga cognitiva (Sweller, 1988), la optimización del diseño instruccional permite reducir la sobrecarga cognitiva y mejorar la eficiencia del aprendizaje mediante el uso adecuado de tecnologías educativas.

Asimismo, enfoques como el socioconstructivismo de Vygotsky resaltan la importancia del andamiaje pedagógico en el desarrollo del aprendizaje, destacando el papel del docente y de las herramientas tecnológicas como mediadores del proceso formativo. De manera complementaria, la teoría de la autodeterminación (Deci y Ryan, 1985) y los estudios sobre autoeficacia (Bandura, 1997) señalan que la motivación intrínseca y la percepción de competencia del estudiante son factores determinantes en el desarrollo de la autonomía académica.

En esta línea, Martínez Cardero (2024) sostiene que el estudiante debe ser comprendido como un agente activo de su propio aprendizaje, donde la inteligencia artificial actúa como un sistema de apoyo que facilita la toma de decisiones informadas, sin sustituir el rol cognitivo ni la agencia del aprendiz. Esta perspectiva se alinea con los enfoques contemporáneos de diseño instruccional centrado en el estudiante, en los cuales se prioriza la autonomía, la personalización del aprendizaje y el uso ético de sistemas inteligentes.

La IA como herramienta para el aprendizaje individualizado

Sistemas de aprendizaje adaptativo

Los sistemas de aprendizaje adaptativo impulsados por IA se destacan como una de las formas más avanzadas de personalización educativa. Estos sistemas se definen por su capacidad para adaptar dinámicamente el contenido, la secuenciación, el ritmo y las estrategias pedagógicas a las necesidades únicas del aprendiz. A diferencia de los enfoques tradicionales basados en ramificaciones predeterminadas, los sistemas modernos utilizan algoritmos de aprendizaje que mejoran continuamente a partir de interacciones y recalibran sus modelos predictivos para optimizar mejor la experiencia de entrenamiento (Santillán Lima et al., 2024).

Un análisis de investigaciones recientes muestra que hay una mayor diversificación en las variables utilizadas para la adaptación. Mientras que los primeros sistemas se centraban principalmente en el dominio conceptual, las plataformas contemporáneas también utilizan dimensiones motivacionales, metacognitivas, contextuales e incluso socioculturales para crear recomendaciones más personalizadas. Las implementaciones más sofisticadas en matemáticas integran simultáneamente: conocimiento previo, patrón de error predominante, tiempo de respuesta, estados emocionales inferidos, estilo de aprendizaje y preferencias representacionales (Panqueban y Huincahue, 2024).

Sin embargo, Caballero Alarcón y Brítez Carli (2024) advierten sobre la brecha entre la sofisticación algorítmica y la base pedagógica que sustenta muchos sistemas. Su análisis de 18 plataformas utilizadas en instituciones de América Latina revela que tan solo un tercio articula sus mecanismos adaptativos junto con teorías educativas sólidas, mientras que los enfoques instrumentales que priorizan la eficiencia sobre el aprendizaje cualitativamente transformador dominan.

Minería de datos educativos para la personalización

Junto con el núcleo de la personalización impulsada por IA, el análisis de datos educativos está pasando del modelo descrito a modelos predictivos y prescriptivos. Bustamante Bula y Camacho Bonilla (2024) argumentan que las instituciones educativas modernas hoy producen cantidades sin precedentes de datos multimodales que, si se procesan adecuadamente, hacen posible construir perfiles multidimensionales de los estudiantes e identificar patrones que antes estaban más allá del alcance de la observación humana.

La literatura más reciente documenta diversas aplicaciones de la analítica educativa para la personalización. Por un lado, estudios como el realizado por Galarza Ramírez et al. (2024) demuestran cómo el análisis de patrones de navegación de usuarios, duración de actividad y secuencias de interacción permite la identificación probabilística de ventanas óptimas de intervención pedagógica. Por otro lado, Lancheros-Bohorquez y Vesga-Bravo (2024) ilustran el potencial de combinar el análisis de texto con el reconocimiento de emociones para proporcionar apoyo contextual tras la identificación temprana de frustraciones específicas matizadas utilizando métodos sofisticados.

Una tendencia emergente particularmente prometedora es la evolución de los modelos estáticos a “gemelos digitales” en constante desarrollo. Estas representaciones complejas, en capas multidimensionales, y más allá del rendimiento escolar, incluyen intereses y preferencias, estados motivacionales e incluso, contextos en constante cambio. Rasgos que permiten una personalización en respuesta a la naturaleza dinámica del aprendizaje humano (Isea Arguelles et al., 2024).

Retroalimentación automatizada y tutores inteligentes

Los tutores inteligentes son quizás la manifestación más plena del aprendizaje personalizado en IA; han evolucionado de ser meros secuenciadores de contenido a sofisticados asistentes pedagógicos de diálogo. Con el reciente auge en modelos de lenguaje y arquitectura de transformadores, estos sistemas han podido sostener interacciones más fluidas y adaptativas, mejorando sustancialmente sus capacidades de diálogo (Arias-Chávez et al., 2024).

La retroalimentación proporcionada por los tutores ha mejorado de manera progresiva. Rodríguez Ramírez et al. (2024) sostienen que los mejores sistemas contemporáneos han evolucionado hacia modelos que ya no ofrecen retroalimentación binaria (acierto/fracaso). En su análisis de retroalimentación cualitativa, estos sistemas diagnostican patrones de error; explican los procesos subyacentes con mayor nivel de comprensión; proponen estrategias de metacognición adaptativa; y utilizan motivación diferenciada ajustada al perfil del estudiante.

El uso de tutores inteligentes enfrenta situaciones adversas. Quinde Rosales et al. (2024) comentan que la percepción estudiantil respecto a los sistemas de tutoría varía según el diseño. Los sistemas que otorgan transparencia algorítmica y control activo al usuario son bien aceptados. En cambio, las “cajas negras” generan desconfianza y resistencia. La tutoría inteligente debe facilitar la confianza, lo que conlleva no solamente optimizar indicadores de confianza, sino establecer relaciones pedagógicas en las que los estudiantes de verdad puedan involucrarse de manera activa.

"El uso de la inteligencia artificial en la educación: desafíos y oportunidades" comenta que la personalización de IA para educación se encuentra en un estado prometedor, aunque con matices sobre su efectividad. El documento menciona que, en entornos controlados estandarizados, optimizan el rendimiento en los dos extremos del espectro.

Este aspecto ha sido abordado por Caballero-Alarcón y Brítez-Carli (2024), quienes señalan que la efectividad de la IA en educación depende de las condiciones de implementación, la mediación pedagógica y la articulación institucional. Por tanto, los beneficios asociados a la personalización no deben interpretarse como efectos automáticos de la tecnología, sino como resultados condicionados por el diseño educativo y el contexto de aplicación.

De todas formas, la efectividad es contextual y difiere drásticamente según las modalidades de implementación. Castro et al. (2024) señalan que los aprendizajes derivados del trabajo en laboratorio se diluyen cuando se amplían a contextos más complejos, debido a factores como infraestructura y sistemas de soporte insuficientes, ausencia docente, resistencia cultural y superficialidad en las modificaciones implementadas. En este sentido, la ausencia de tecnología no constituye el problema central; por el contrario, el hallazgo resulta particularmente revelador al evidenciar la falta de correlación directa entre disponibilidad tecnológica y mejora educativa. La baja articulación institucional genera efectos pedagógicamente contraproducentes, por lo que ninguna de las herramientas propuestas resulta plenamente pertinente en contextos de implementación sistémicamente desarticulados.

Un aspecto crítico documentado por Alfaro Salas y Díaz Porras (2024) se refiere a la secuenciación temporal de efectos: mientras que los resultados inmediatos tienden a ser favorables, los estudios longitudinales están revelando patrones más complejos, incluyendo posibles dependencias autodestructivas en contextos donde la automatización no evoluciona con autonomía.

Limitaciones y Desafíos Identificados

A pesar del potencial transformador de la IA en la personalización del aprendizaje, la literatura señala que persisten brechas significativas que requieren atención sistemática y sostenida. Una preocupación principal se refiere a los sesgos algorítmicos que pueden sostener o exacerbar las inequidades existentes. Alfaro Salas y Díaz Porras (2024) documentan cómo los algoritmos entrenados en conjuntos de datos históricos tienden a perpetuar patrones discriminatorios previos, proporcionando recomendaciones que refuerzan estereotipos socioeconómicos, étnicos o de género.

Otra limitación críticamente definitoria incluye lo que Rodríguez Ramirez et al. (2024) se refieren como "personalización superficial." Sistemas que ajustan características superficiales de la experiencia educativa sin cambios significativos en los marcos pedagógicos subyacentes. En tales casos, la tecnología funciona meramente como un complemento a los modelos tradicionales y pierde la capacidad de transformar.

Para el año 2024, Castro et al. (2024), plantean que los sistemas actuales, si bien son sofisticados en el manejo de patrones cognitivos, presentan brechas significativas en la comprensión contextual. Esto implica que no son capaces de integrar socioculturalmente los aspectos emocionales y situacionales que son factores determinantes en los procesos reales de aprendizaje.

Al respecto, Bustamante Bula y Camacho Bonilla (2024), enfatizan que la recientemente emergente tecnología también promueve el balance entre personalización y experiencia social del aprendizaje. Sin embargo, advierten sobre consecuencias no deseadas de la

hiperpersonalización. Esta, al ser llevada al extremo, pudiera fragmentar comunidades de aprendizaje.

La IA es uno de los avances para el siglo XXI, que, junto con la promoción de la autonomía estudiantil, han sido objeto de nuevas investigaciones. Analizando temas como “Mecanismos de apoyo a la autorregulación”, nuevos conceptos han surgido para el desarrollo de capacidades autorregulatorias - impulsadas por la IA - que son determinantes para la autonomía estudiantil. Desde esta perspectiva, estos mecanismos se dividen entre la fase de planificación, ejecución y reflexión del ciclo de autorregulación propuesto por Zimmerman.

En la fase de planificación, los sistemas de IA ofrecen herramientas de establecimiento de objetivos que asisten en la toma de decisiones a través de visualizaciones personalizadas del dominio, recomendaciones adaptativas y planes que toman en cuenta los patrones de aprendizaje previos (Aguirre-Aguilar et al., 2024). Asistentes que ayudan a descomponer tareas complejas en subobjetivos manejables y cronogramas realistas son particularmente innovadores.

Durante la ejecución, la IA mejora el monitoreo continuo a través de tableros personalizados, alertas adaptativas durante momentos críticos, y retroalimentación formativa contextual proporcionada en tiempo real. Martínez Cardero (2024) reporta sobre sistemas que detectan patrones sutiles de desconexión mucho antes de que sean notables para los instructores humanos, permitiendo intervenciones proactivas oportunas. Al mismo tiempo, los asistentes conversacionales brindan apoyo metacognitivo al hacer preguntas personalizadas que fomentan la reflexión sobre las estrategias empleadas.

En la fase de autorreflexión, las tecnologías de IA permiten un análisis retrospectivo en profundidad al reconstruir trayectorias de aprendizaje, analizar las brechas entre la ejecución y la planificación, y detectar patrones recurrentes dentro de las escalas de acciones (Villamar Ponce et al., 2024). Estos sistemas que capturan datos de rendimiento y los convierten en narrativas personalizadas proporcionan a los estudiantes una comprensión coherente y longitudinal de su progreso y destacan el potencial holístico de los sistemas.

El andamiaje decreciente ha cobrado especial relevancia en la literatura reciente. Acercarse a la figura que reduce el apoyo gradual durante la actividad constructiva de aprendizaje autorregulador resulta más efectivo en el desarrollo de autonomía sostenible en comparación con aquellos andamiajes que constan de niveles permanentes de asistencia (Lancheros-Bohorquez y Vesga-Bravo, 2024).

Desarrollo de habilidades metacognitivas asistidas por IA

La autonomía de aprendizaje está relacionada con la tenencia de habilidades metacognitivas, entendidas como capacidades para monitorear, evaluar y ajustar los distintos procesos cognitivos en los que el estudiante se encuentra involucrado activamente. La literatura reciente reporta el uso de la IA para el desarrollo sistemático de tales capacidades más allá de la instrucción explícita tradicional.

Un enfoque prominente se relaciona con lo que Aguirre-Aguilar et al. (2024) quienes argumentan que se trata de “espejos cognitivos aumentados”: sistemas que recopilan, procesan y visualizan datos que permiten hacer observables y por ende, modificables: los patrones de pensamiento del estudiante. Estas visualizaciones van más allá de simples métricas de rendimiento y también incluyen aspectos procesales como: las secuencias de razonamiento, el tiempo que se pasa en las distintas actividades cognitivas, los patrones de revisión y la evolución de las representaciones conceptuales a lo largo del tiempo.

Asimismo, los asistentes conversacionales de última generación utilizan técnicas socráticas de provistas. Estos sistemas no solo contestan preguntas, sino que también utilizan procesos metacognitivos tales como modelado, justificación, detección de contradicciones, y proponen verificaciones (Arias-Chávez et al., 2024). La capacidad de estos asistentes en modular el grado de intervención que ofrecen de acuerdo con el proceso que el estudiante esté llevando a cabo resulta enormemente útil en la evolución progresiva de la autorregulación.

Rodríguez Ramírez et al. (2024) describen como una tendencia emergente el uso hacia el, metacognición con aprendizaje colaborativo a través de 'social pedagogical agents' que estimulan el uso de la reflexión colectiva. Estos sistemas hacen posible la expresión explícita de las estrategias por parte de los pares, la co-regulación del aprendizaje, así como la comparación constructiva de diferentes enfoques y la confrontación de estrategias, ampliando la dimensión social que se suele pasar por alto en las aplicaciones de IA educativa individualistas.

Evidencias empíricas sobre impacto en la autonomía

Las evidencias empíricas sobre la autonomía estudiantil a partir del uso de IA dibujan un panorama denso lleno de complejidades e contradictorios resultados relacionados al contexto, diseños tecnopedagógicos y características del alumnado. Estudiar esta problemática desde enfoques multidisciplinares revela tendencias que desafían suposiciones simplistas sobre la relación transversal la tecnología y la autonomía.

Villamar Ponce et al. (2024) realizaron un análisis longitudinal sobre la evolución de las métricas de autorregulación en estudiantes universitarios sometidos a diferentes tipos de exposiciones a sistemas adaptativos. Sus hallazgos sugieren que la mera exposición a entornos personalizados no fomenta el desarrollo de la auto-autonomía; más bien, los sistemas altamente personalizados pero opacos en sus mecanismos de toma de decisiones pueden crear dependencias contraproducentes. Se observó el máximo beneficio en entornos que integraban los tres atributos: transparencia algorítmica, transferencia gradual de control al aprendiz y reflexión explícita sobre los procesos decisionales.

Desde la perspectiva cuantitativa, Caballero Alarcón y Brítez Carli (2024) reportan impactos moderados pero significativos en las métricas de autonomía ($d=0.47$) para implementaciones que incorporan de manera intencionada estrategias metacognitivas en su diseño, a diferencia de los impactos insignificantes o negativos en sistemas enfocados únicamente en la optimización del contenido. Estas diferencias destacan la necesidad de un diseño intencionado para aprovechar el potencial de la IA, lo que subraya el enfoque en las eficiencias inmediatas.

Las percepciones de los estudiantes son particularmente reveladoras. Quinde Rosales et al. (2024) documentan percepciones ambivalentes: mientras que varios estudiantes aprecian el apoyo adaptativo, al mismo tiempo expresan preocupaciones sobre las recomendaciones algorítmicas excesivamente dependientes que limitan el desarrollo de su juicio independiente. Estas tensiones destacan la necesidad de enfoques que cultiven una crítica explícita de los tecnosistemas en uso.

Las tensiones entre la personalización y la autonomía se desarrollan

La nueva literatura revela tensiones fundamentales entre la inmediatez de los objetivos de personalización y la autonomía a largo plazo como centro de control. Alfaro Salas y Díaz Porras (2024) identifican una posible contradicción epistemológica: la personalización avanzada selecciona de manera óptima caminos hacia objetivos predeterminados al minimizar obstáculos. El desarrollo del funcionamiento autónomo, contraintuitivamente, requiere enfrentar luchas productivas. Los sistemas que eliminan completamente la fricción cognitiva corren el riesgo de

no proporcionar las oportunidades necesarias para desarrollar resiliencia y autorregulación frente a demandas desafiantes.

A nivel práctico, Martínez Cardero (2024) documenta que sistemas altamente personalizados pueden generar 'burbujas pedagógicas,' análogas a burbujas informativas: entornos tan perfectamente ajustados a preferencias actuales que limitan la exposición a perspectivas y desafíos variados. Paradójicamente, cierto grado de despersionización estratégica podría proveer mayores beneficios al aumentar la versatilidad.

Quizás la tensión más fundamental concierne al locus de control decisional. Los sistemas que automatizan de manera excesiva decisiones pedagógicas sin un escalonamiento en el otorgamiento de contribuciones evaluativas, progresivamente, ancladas en las decisiones del estudiante, producen dependencias sofisticadas. Bustamante Bula y Camacho Bonilla (2024) advierten de la 'autonomía ilusoria' en que caen muchos estudiantes: "Situaciones cuando alumnos erróneamente, o mejor dicho, de forma superficial, perciben como propias decisiones en realidad determinadas de forma algorítmica," desarrollando en llave "agencia delegada" en lugar de autonomía.

Factores Críticos de Éxito

La revisión de la literatura integrada analiza el contexto estadounidense y destaca factores que abordan específicamente el fracaso de capitalizar plenamente el potencial de la IA en el fomento de la autonomía del estudiante más allá de enfoques tecnocéntricos simplistas. Estos factores aparecen con frecuencia en la investigación sobre resultados positivos.

Detrás del primer factor está la concepción y el diseño explícito de la "transparencia pedagógica" que debe ser habilitada en los sistemas de IA educativa. Las implementaciones exitosas no solo hacen visibles las decisiones algorítmicas, sino que también las transforman en oportunidades de aprendizaje metacognitivo que ayudan al aprendiz a comprender la lógica subyacente a las recomendaciones, para que puedan formar criterios evaluativos independientes (Rodríguez Ramírez et al., 2024).

El segundo determinante se relaciona con lo que Galarza Ramírez et al. (2024) conceptualizan como "equilibrio de agencia": la distribución dinámica y evolutiva del control entre el algoritmo, el docente y el aprendiz. Los sistemas que hacen explícita esta distribución y otorgan progresivamente el control al aprendiz muestran resultados a largo plazo en autonomía desarrollada significativamente mejores.

El currículo integrado sistemático se destaca como el tercer factor crítico. Martínez Cardero (2024) documenta que disfrutar del complemento de implementaciones aisladas como herramientas suplementarias produce beneficios limitados en comparación con haber transformado el proceso de enseñanza y aprendizaje donde la IA se incorpora como parte integral de todo el ecosistema pedagógico diseñado y alineado con los objetivos programáticos de desarrollo de la autonomía.

La capacitación docente se mantiene como el factor más relevante. Como señalan Alfaro Salas y Díaz Porras (2024), el impacto positivo de las mismas herramientas tecnológicas se ve drásticamente mitigado por la capacidad del educador para mediar de manera transformativa a nivel del sistema-estudiante; para transformar análisis e información algorítmica en diálogos significativos sobre metacognición y autorregulación.

Implicaciones Pedagógicas y Organizativas

Transformación del rol docente

El uso efectivo de la IA para personalizar el aprendizaje y fomentar la independencia del aprendiz acelera una profunda reconceptualización del rol docente y lo lleva de la transmisión de información a roles más complejos y sofisticados. Este cambio no significa simplemente agregar nueva tecnología a las prácticas existentes; requiere una reconstrucción fundamental de la identidad profesional del docente.

Se ha informado por Alfaro Salas y Díaz Porras (2024) que los educadores en contextos de alta integración tecnológica se adaptan a roles multidimensionales, como diseñadores de experiencias adaptativas, intérpretes de análisis complejos, mediadores de necesidades humanas y sistemas algorítmicos, y asesores en metacognición aplicada al diseño instruccional, que contribuyen a la construcción y evaluación de algoritmos educativos. Particularmente relevante resulta la capacidad de contextualizar conjuntos de datos altamente complejos en narrativas pedagógicas significativas para el estudiante.

Castro et al. (2024) observa cómo el impacto de la tecnología en la educación difiere según la posicionalidad del educador. Contrario a las narrativas simplistas sobre el fenómeno de “la automatización educativa”, el uso de entornos fomentados por IA sugiere un paradigma en aumento, simbiótico con la pedagogía humana, que requiere procedimientos de enseñanza sofisticados.

Surge una brecha significativa entre estas demandas y las estructuras de capacitación docente predominantes en la literatura. Los autores argumentan que solo el 12% de los programas de capacitación docente contemporáneos abordan efectivamente las expectativas del rol para los docentes en los ecosistemas educativos de IA. Esta brecha ilustra las insuficiencias de las expectativas institucionales, lo que sugiere una necesidad urgente de reestructurar radicalmente los procesos de desarrollo profesional docentes alineados con las realidades emergentes de la IA.

El uso de la IA junto a otras tecnologías emergentes se extiende más allá de personalizar las trayectorias de aprendizaje para la autonomía, transformando fundamentalmente los procesos de diseño instruccional. Surge un desplazamiento de los modelos lineales de instrucción hacia arquitecturas modulares con granularidad multiescalar y trayectorias adaptativas.

Martínez Cardero (2024) yuxtapone el diseño instruccional convencional, que exige una secuencia predeterminada, con paradigmas emergentes de “metadiseño” que presentan componentes recombinables y parámetros flexibles dentro de los cuales los sistemas inteligentes pueden generar dinámicamente experiencias personalizadas. Este enfoque requiere la conceptualización del contenido como redes semánticas multidimensionales en lugar de secuencias lineales.

Un aspecto crítico emerge en lo que Rodríguez Ramírez et al. (2024) denominan “diseño de segundo orden”: la elaboración no solo de experiencias directas sino también de las condiciones bajo las cuales los sistemas inteligentes generan continuamente experiencias optimizadas. Este enfoque requiere tanto capacidades tecnológicas como conceptuales para articular formalmente detalles tradicionalmente implícitos del diseño instruccional.

Particularmente desafiante es integrar dimensiones socio-emocionales en estos nuevos modelos, dado que los enfoques tecnológicos a menudo descuidan este aspecto. Las prácticas más prometedoras documentadas por Galarza Ramírez et al. (2024) combinan personalización algorítmica y diseño intencional de interacciones humanas complementarias, reconociendo que algunos aspectos formativos fundamentales requieren una presencia social auténtica que no es sustituible tecnológicamente.

Requisitos institucionales para la implementación

La implementación efectiva de ecosistemas educativos de IA para la personalización y fomento de la autonomía permite profundas transformaciones organizativas que van más allá de consideraciones puramente tecnológicas. La literatura apunta a requisitos institucionales críticos en iniciativas de innovación que son frecuentemente pasados por alto.

A nivel infraestructural, además de evidentes necesidades tecnológicas, emergen requerimientos significativos en gestión de datos educativos: estructuras robustas de gobernanza que garantizan la integridad, accesibilidad, interoperabilidad y cumplimiento normativo, especialmente en contextos con regulaciones estrictas sobre información estudiantil. (Zambrano Noboa et al. según Bustamante Bula y Camacho Bonilla, 2024)

A nivel organizacional, el éxito en las implementaciones evidencia reorganizaciones que cruzan las fronteras de silos en tecnología educativa hacia enfoques colaborativos inclusivos de pedagogos, especialistas técnicos, analistas de datos y expertos en experiencias estudiantiles. Isea Arguelles et al. (2024) documentan correlación directa entre efectividad de implementación y existencia de estructuras formales de colaboración multidisciplinaria para estos grupos profesionales.

Quizás el requerimiento más fundamental concierne al alineamiento estratégico institucional. Castro et al. (2024) identifican que transformaciones sostenibles ocurren únicamente en condiciones en las que la implementación de tecnología sucede dentro del marco de una visión educativa coherente, articulada explícitamente con la misión institucional y aliada a un liderazgo a largo plazo. Esta observación explica por qué iniciativas sofisticadas a nivel técnico, pero carentes de un anclaje en prioridades estratégicas, suelen fallar o tener efectos elusivos en su alcance.

Requisitos de formación docente

Hemos visto que la formación docente es el único factor que tiene el potencial de convertir las numerosas oportunidades proporcionadas por la IA en cambios educativos transformadores reales. La literatura señala una brecha crítica entre las competencias requeridas para ecosistemas educativos aumentados por IA y los programas de formación actuales.

Alfaro Salas y Díaz Porras (2024) proponen un marco multicomponente de competencias específicas que consideran necesarias, que incorpora: alfabetización específica para la implementación de IA educativa (no genérica); habilidades para diseñar experiencias que aumenten las capacidades algorítmicas; habilidades avanzadas de interpretación de analíticas de aprendizaje; competencias de mediación entre necesidades contextuales y recomendaciones algorítmicas; y alfabetización crítica para evaluar las implicaciones éticas de implementaciones tecnológicas particulares.

La modalidad de formación es igualmente crítica. Martínez Cardero (2024) contrasta modelos tradicionales basados en formación episódica con emergentes de “formación inmersiva continua” donde los educadores se someten activamente a entornos adaptativos mientras construyen las capacidades para diseñar e implementar tales contextos. Estos enfoques meta-formativos crean una comprensión vivida de las transformaciones cualitativamente diferentes que son posibles a través de la personalización inteligente.

Son notables los modelos innovadores de formación docente que incluyen la auto-adaptación de la experiencia de aprendizaje. Caballero Alarcón y Brítez Carli (2024) relatan casos en los que sistemas de IA analizan prácticas docentes específicas, identifican áreas potenciales de

crecimiento y construyen planes de formación personalizados que se alinean precisamente con las necesidades contextuales de cada educador.

Ética y aspectos socioeducativos

Protección y privacidad de datos

La IA avanzada y la personalización junto con el desarrollo de autonomía asistida crean tensiones fundamentales con la privacidad y protección de datos, especialmente en el entorno educativo que involucra menores. Estas tensiones son más que técnicas o normativas, son fundamentalmente éticas y sociopolíticas.

En el primer nivel, los sistemas de IA educativa generan un seguimiento sin precedentes de datos granulares de comportamiento, preferencias, dificultades cognitivas y atributos personales, acumulando datos que antes no existían. Alfaro Salas y Díaz Porras (2024) advierte que la “huella digital educativa” que se gesta al consumo de recursos edtech brinda a familias y estudiantes beneficios inmediatos, pero carecen de comprensión cuando se observan las implicancias a largo plazo de estos registros detallados sobre trayectorias futuras.

El segundo nivel se relaciona con lo que Bustamante Bula y Camacho Bonilla (2024) denominan “consentimiento significativo” en contextos más complejos. Ellos argumentan que las estructuras tradicionales de consentimiento resultan insuficientes cuando enfrentan la doble calle del: a) escaso dominio del contexto sobre el alcance de la recopilación de datos; b) presión institucional, ya sea implícita o explícita; y c) imposibilidad algorítmica de prever todas las potenciales futuras utilidades de la información proporcionada.

El equilibrio entre los requerimientos de transparencia algorítmica que garantizan una autonomía auténtica y los de privacidad resulta particularmente desafiante. Los sistemas completamente abiertos que permiten la inspección y auditoría total de sus mecanismos decisionales exponen inevitablemente información sensible recabada a su profilización (Rodríguez Ramírez et al., 2024). Esta tensión pone en evidencia la insuficiencia de enfoques dicotómicos que no aprecian las múltiples dimensiones de estas problemáticas

Equidad e inclusión digital

La inteligencia artificial que fundamenta la personalización de contenido y la promoción de formas de autonomía trae consigo la posibilidad de amplificar desigualdades preexistentes, lo cual, en caso de no ser intencionadamente diseñado para equidad, se vuelve un riesgo significativo. La literatura identifica múltiples mecanismos mediante los cuales innovaciones aparentemente neutrales pueden exacerbar brechas educativas existentes.

A nivel infraestructura, Galarza Ramírez et al. (2024) documentan que el uso de nuevas tecnologías intensivas suele acentuar la posición hegemónica de las instituciones y estudiantes que gozan de robusta conectividad, dispositivos adecuados y clases preparados a nivel físico propicias para el aprendizaje altamente digitalizado. Estas disparidades resultan particularmente pronunciadas en contextos latinoamericanos con brechas digitales significativas entre entornos urbanos y rurales, así como entre instituciones públicas y privadas.

Desde una perspectiva algorítmica, Alfaro Salas y Díaz Porras (2024) están particularmente preocupados por los sesgos sistemáticos que surgen cuando los sistemas de IA se entrenan principalmente con datos de poblaciones privilegiadas o mayoritarias. Estos sesgos crean un perverso “circuito de retroalimentación de desigualdad de equidad” donde los estudiantes subrepresentados reciben recomendaciones subóptimas que dificultan su progreso, confirmando estereotipos arraigados en los algoritmos.

Lo que resulta aún más preocupante es lo que Castro et al. (2024) se refieren como "personalización estratificada": implementaciones donde la personalización es menos rica para algunos grupos demográficos, reduciendo así su calidad y profundidad para ellos. Dentro de este fenómeno, puede haber sutilezas en la complejidad de las recomendaciones, la riqueza de la retroalimentación y la autonomía promovida entre segmentos.

Sesgo algorítmico en la educación

Los sesgos en los sistemas de IA educativa plantean un desafío ético en su implementación y uso, manifestándose de maneras complicadas que trascienden un análisis técnico superficial. La literatura destaca numerosas formas en que estos sesgos pueden surgir y propagarse dentro de contextos formativos educativos.

A un nivel fundamental, Rodríguez Ramírez et al. (2024) afirman que los sistemas de IA inevitablemente incorporan concepciones específicas de lo que constituye "aprendizaje exitoso", "progreso apropiado" o "autonomía deseable". Estas conceptualizaciones, que están lejos de ser neutras o universales, reflejan valores culturales particulares, paradigmas pedagógicos específicos, así como prioridades institucionales marcadas. Como consecuencia, incluso los algoritmos "imparciales" desde el punto de vista técnico pueden, insidiosamente, si normativamente, arraigar visiones prescriptivas problemáticas configuradas sobre el desarrollo educativo.

Más específicamente, Alfaro Salas y Díaz Porras (2024) documentan que los sistemas predictivos basados en datos históricos tienden a reproducir patrones existentes de discriminación. Por ejemplo, los algoritmos que utilizan métricas de "éxito" previas como base para personalizar recomendaciones a menudo perpetúan bajas expectativas para estudiantes de grupos históricamente marginados, restringiendo sistemáticamente las experiencias ricas y atractivas que se ofrecen.

Los sesgos interseccionales, donde múltiples factores se superponen e interactúan de maneras complejas, son especialmente desafiantes. Bustamante Bula y Camacho Bonilla (2024) muestran cómo los sistemas que funcionan para la mayoría parecen fallar sistemáticamente a estudiantes que poseen características específicas simultáneamente (por ejemplo, un trasfondo de lengua dominante combinado con patrones cognitivos atípicos), creando lo que llaman "puntos ciegos algorítmicos", donde la personalización efectivamente desaparece para ciertos perfiles de estudiantes.

Equilibrio humano-máquina en el proceso educativo

La ética que acompaña la integración de componentes humanos y algorítmicos en los entornos educativos ecosistemas consideran su combinación como algo que supera dicotomías maniqueas. El corpus teórico existente demuestra que este equilibrio en bio-educación es una aproximación diversificada que reconozca las complementariedades entre la humanidad y la tecnología.

Castro et al. (2024) propone un marco analítico en cinco dimensiones sobre la toma de decisiones pedagógicas y quien determina trayectorias, intervenciones y evaluaciones en su marco: mediación socioafectiva (cómo se atienden necesidades emocionales, motivacionales y relacionales); construcción de significado (explícito o implícito en la generación cierta de interpretaciones de los datos y eventos); emersión o adaptación a contextos culturales y particularidades socioculturales, y modelado ético de valores y principios.

Martínez Cardero (2024) documenta que las implementaciones más efectivas no maximizan simplemente eficiencia algorítmica, sino que diseñan deliberadamente "interfaces humano-

máquina” donde se decide estratégicamente qué aspectos formativos se algoritmizarán y cuáles permanecerán en dominio humano. Estas decisiones no son meramente técnicas, sino fundamentalmente axiológicas, reflejando visiones específicas sobre educar y, la esencia de aprender.

Particularmente reveladora es la idea de complementariedad asimétrica proporcionada por Alfaro Salas y Díaz Porras (2024): la observación de que algunos elementos constitutivos formativos—especialmente aquellos que pertenecen a dimensiones éticas, creativas y existenciales del aprendizaje—requieren una presencia humana no algorítmica. Este punto de vista contrasta con otros que asumen que la presencia humana es simplemente un “complemento temporal” hasta que se logra una suficiencia algorítmica.

Marco normativo y gobernanza de la IA educativa

El uso ético responsable de sistemas de IA para la personalización y el desarrollo de la autonomía requiere marcos de guía proactivos y estructuras de gobernanza que vayan más allá de enfoques reactivos. La literatura describe brechas significativas entre las realidades tecnológicas emergentes y los ecosistemas regulatorios predominantes.

Desde el punto de vista regulatorio, Bustamante Bula y Camacho Bonilla (2024) documentan una fragmentación significativa y un retraso temporal respecto a la norma de educación sobre IA en el contexto latinoamericano. Mientras que algunas jurisdicciones carecen de leyes específicas, aplicando regulaciones genéricas de manual que no logran captar las complejidades de la educación, otras presentan superposiciones contradictorias en la protección de datos, derechos educativos y marcos legales sectoriales propietarios. Más allá de otros aspectos formales, Castro et al. (2024) expresan la necesidad de modelos de gobernanza participativos que gestionen algorítmicamente sistemas que involucren una considerable participación de partes interesadas relevantes: estudiantes, maestros, familias, administradores, desarrolladores y la comunidad. Esta perspectiva contrasta con modelos tecnocráticos que fundamentalmente confían la toma de decisiones éticas y pedagógicas a expertos técnicos o administrativos.

La definición de Rodríguez Ramírez et al. (2024) sobre “evaluación de impacto algorítmico educativo” es particularmente prometedora: se refiere a procesos sistemáticos que evalúan la evaluación multidimensional de implementaciones específicas de antemano. Estos procesos transforman consideraciones éticas de reflexiones abstractas post-diseño en componentes activos del diseño operativo.

4. Discusión

Síntesis integradora de hallazgos

La presente revisión sistemática de la literatura sobre inteligencia artificial (IA), aprendizaje autodirigido y personalización educativa sugiere que, aunque existen avances significativos, persisten tensiones y desafíos emergentes en la implementación de estas tecnologías. La evidencia revisada indica que los impactos de la IA son altamente contextuales, dependiendo más de las decisiones de implementación y del diseño pedagógico que de las características técnicas de los algoritmos en sí (véase artículos 1, 3 y 6 en Tabla 2).

En relación con el aprendizaje autodirigido, se observa en la literatura que los sistemas contemporáneos facilitan una personalización multidimensional, abarcando dimensiones cognitivas, metacognitivas, motivacionales y contextuales. Sin embargo, se reporta una brecha

considerable entre la sofisticación tecnológica de los algoritmos y la solidez pedagógica de su aplicación, lo que con frecuencia conduce a implementaciones técnicamente avanzadas, pero conceptualmente superficiales (artículos 2, 4 y 7).

Respecto a la autonomía estudiantil, la evidencia sugiere que su potenciación mediante IA depende críticamente de diseños que sean transparentes, transfieran gradualmente el control al aprendiz, integren explícitamente el desarrollo metacognitivo y reconozcan la diversidad de contextos y estilos de aprendizaje (artículos 3, 5 y 10). Se observa que mientras algunos estudios destacan la capacidad de la IA para habilitar decisiones autodirigidas y caminos educativos personalizados, otros cuestionan la posibilidad de auténtica autonomía cuando las opciones están predeterminadas por algoritmos con lógicas poco transparentes (artículos 8, 12 y 14).

Desde una perspectiva ética, se reportan preocupaciones sobre equidad algorítmica, privacidad de los datos y la preservación de elementos humanos esenciales en la educación. La literatura sugiere que estos aspectos no son meramente técnicos o regulatorios, sino que implican decisiones axiológicas sobre los propósitos educativos en sociedades democráticas (artículos 6, 9 y 11).

Los hallazgos muestran también tensiones entre estandarización y diversificación. Algunos autores consideran que la personalización basada en IA debe maximizar la adecuación individual de la experiencia educativa, mientras otros advierten que un exceso de fragmentación podría afectar elementos fundamentales compartidos necesarios para la cohesión social (artículos 1, 5, 7 y 13).

La revisión revela vacíos significativos que requieren investigación adicional. Se observa una escasez de estudios longitudinales robustos sobre los efectos a largo plazo de entornos personalizados por IA, así como una comprensión limitada de cómo las dimensiones socioculturales influyen en la autonomía y la personalización, especialmente en contextos latinoamericanos (artículos 3, 12 y 15). Además, se reporta una brecha entre la teorización técnica y la comprensión pedagógica profunda, evidenciando la necesidad de marcos conceptuales interdisciplinarios que integren perspectivas computacionales, psicológicas y educativas (artículos 2, 4, 8 y 14).

Finalmente, se observa que las metodologías predominantes, centradas en métricas cuantitativas inmediatas, pueden ser insuficientes para capturar impactos complejos sobre la metacognición, la experiencia educativa y el desarrollo socioafectivo. La literatura sugiere que se requieren aproximaciones mixtas y más sofisticadas para evaluar adecuadamente los efectos multidimensionales de la IA en personalización y autonomía (artículos 6, 9 y 13).

En síntesis, la evidencia sugiere que la IA tiene potencial para apoyar la personalización educativa y la autonomía estudiantil, pero su efectividad depende de un diseño pedagógico cuidadoso, del contexto sociocultural y de la integración de consideraciones éticas. Estos hallazgos se alinean con los patrones observados en los artículos incluidos en la Tabla 2 y constituyen un marco para futuras investigaciones que busquen comprender mejor las implicaciones de la IA en la educación.

Limitaciones del estudio

La presente revisión presenta algunas limitaciones. En primer lugar, la búsqueda se restringió a la base de datos Scopus, por lo que pudieron quedar fuera estudios relevantes publicados en otras fuentes académicas. En segundo lugar, la heterogeneidad de los documentos incluidos, compuestos por estudios empíricos, revisiones, marcos conceptuales y análisis institucionales, impidió realizar una comparación estadística de resultados. En tercer lugar, la síntesis se desarrolló de manera narrativa, por lo que los hallazgos deben interpretarse como una

aproximación descriptiva al estado de la literatura y no como una medición causal del impacto de la inteligencia artificial en la personalización del aprendizaje o la autonomía estudiantil.

5. Conclusiones

1. La evidencia sugiere que los sistemas de IA permiten adaptar experiencias de aprendizaje a las necesidades, rasgos y objetivos individuales de los estudiantes. Las implementaciones efectivas tienden a ofrecer retroalimentación contextualizada y modelos multidimensionales del estudiante, mejorando la adecuación pedagógica de las trayectorias de aprendizaje.
2. Se observa que la IA puede apoyar habilidades de auto-regulación y desarrollo metacognitivo, siempre que los sistemas permitan transferencia gradual de control al estudiante, transparencia en la toma de decisiones y opciones reales para moldear su experiencia. No obstante, estos beneficios dependen del diseño y del contexto de implementación, y no se presentan de manera automática.
3. La evidencia indica que la efectividad de los sistemas depende de factores pedagógicos, culturales y sociales. La personalización y la autonomía son más efectivas cuando se consideran aspectos socioculturales, diversidad de trayectorias de aprendizaje y coherencia curricular, evitando la fragmentación excesiva de la experiencia educativa.
4. La literatura sugiere que las implementaciones de IA deben incorporar criterios de equidad, privacidad y participación de los estudiantes en la evaluación de sus procesos de aprendizaje. Esto asegura que la tecnología no solo optimice el desempeño académico, sino que también respalde principios humanistas y democráticos en educación.
5. Se recomienda realizar estudios longitudinales y de investigación-acción que evalúen los impactos sostenidos de la IA en personalización y autonomía, incluyendo dimensiones cognitivas, metacognitivas, motivacionales, socioafectivas y éticas. Además, es necesaria investigación que considere contextos socioculturales específicos, especialmente en entornos latinoamericanos y globales subrepresentados, para validar la eficacia y pertinencia de los sistemas de IA educativa.

Implicaciones

Los hallazgos de esta revisión sistemática tienen importantes implicaciones teóricas y prácticas. Desde el punto de vista teórico, se fortalece la idea de que la mejora continua en educación superior debe concebirse como un proceso sistémico y multidimensional que trasciende los enfoques puramente técnicos para incorporar dimensiones culturales, humanas y contextuales.

A nivel práctico, las instituciones de educación superior deberían priorizar el diseño de modelos híbridos que integren herramientas de Lean y Six Sigma con mecanismos de auto-acreditación y desarrollo del capital intelectual. Asimismo, resulta fundamental fortalecer la formación y el reconocimiento de los líderes académicos y del profesorado como agentes activos de la mejora continua.

Para los responsables de políticas educativas, los resultados sugieren la necesidad de promover marcos regulatorios flexibles que permitan a las IES adaptar los estándares internacionales a sus realidades locales, evitando la aplicación mecánica de modelos externos. Igualmente, se recomienda invertir en el desarrollo de sistemas tecnológicos integrados (como ERP) que faciliten la gestión estratégica de la calidad.

Finalmente, esta investigación subraya la importancia de generar mayor evidencia empírica en contextos latinoamericanos y de economías emergentes, donde la literatura aún es limitada. Futuros estudios deberían explorar la efectividad longitudinal de estos modelos y su impacto real en la calidad de los aprendizajes y la equidad educativa.

6. Referencias

Aguirre-Aguilar, G., Esquivel-Gámez, D., Navarro, R. E., y Veytia-Buchelli, M. G. (2024). La IA en el desarrollo de competencias investigativas en el posgrado. *ALTERIDAD. Revista de Educación*, 19(2), 162-172. <https://doi.org/10.17163/alt.v19n2.2024.01>

Alfaro Salas, H., y Díaz Porras, J. A. (2024). Percepciones del personal docente acerca del uso ético de la inteligencia artificial en su labor educativa. *Revista Innovaciones Educativas*, 26(41), 63-77. <https://doi.org/10.22458/ie.v26i41.4952>

Arias-Chávez, D., Ramos-Quispe, T., y Cangalaya Sevillano, L. M. (2024). Análisis y tendencias en el uso de chatbots y agentes conversacionales en el campo de la educación: una revisión bibliométrica. *Revista Innovaciones Educativas*, 26(41), 242-260. <https://doi.org/10.22458/ie.v26i41.5135>

Bandura, A. (1997). *Self-efficacy: The exercise of control*. W. H. Freeman.

Barrett, R., y Pack, M. (2023). Not quite eye to A.I.: Student and teacher perspectives on the use of generative artificial intelligence in the writing process. *International Journal of Educational Technology in Higher Education*, 20, 59. <https://doi.org/10.1186/s41239-023-00427-0>

Bearman, M., Ryan, G., y Ajjawi, R. (2022). Discourses of artificial intelligence in higher education: A critical literature review. *Higher Education*, 84, 1123–1141. <https://doi.org/10.1007/s10734-022-00937-2>

Belkina, A., Chen, L., y Rodríguez, F. (2025). Implementing generative AI (GenAI) in higher education: A systematic review of case studies. *Computers and Education: Artificial Intelligence*, 8, 100407. <https://doi.org/10.1016/j.caeai.2025.100407>

Bond, M., Marín, V., Dolch, C., Bedenlier, S., y Zawacki-Richter, O. (2024). A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*, 21, 4. <https://doi.org/10.1186/s41239-023-00436-z>

Bustamante Bula, R., y Camacho Bonilla, A. (2024). Inteligencia artificial (IA) en las escuelas: una revisión sistemática (2019-2023). *Enunciación*, 29(1), 62-82. <https://doi.org/10.14483/22486798.22039>

Caballero Alarcón, F. A., y Brítez Carli, R. (2024). Inteligencia Artificial en el mejoramiento de la enseñanza y aprendizaje, Ministerio de Educación y Ciencias. *Academo (Asunción)*, 11(2), 99-108. <https://doi.org/10.30545/academo.2024.may-ago.1>

Castro, A. N., Aguilera, C. A., Medina, J. A., y Prat, M. (2024). Hacia un currículo integrado: conectando la alfabetización en inteligencia artificial con la educación tecnológica en la educación básica en Chile. *Información tecnológica*, 35(6), 39-48. <https://doi.org/10.4067/s0718-07642024000600039>

Chan, C. K. Y. (2023). A comprehensive AI policy education framework for university teaching and learning. *International Journal of Educational Technology in Higher Education*, 20, Article 38. <https://doi.org/10.1186/s41239-023-00408-3>

Chan, C. K. Y., y Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20, Article 43. <https://doi.org/10.1186/s41239-023-00411-8>

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, Article 22. <https://doi.org/10.1186/s41239-023-00392-8>

Dai, K., Liu, Y., y Zhang, X. (2026). Generative AI in higher education: A bibliometric review of emerging trends, power dynamics, and global research landscapes. *Computers and Education: Artificial Intelligence*, Article 100544. <https://doi.org/10.1016/j.caeai.2026.100544>

Deci, E. L., y Ryan, R. M. (1985). *Intrinsic motivation and self-determination in human behavior*. Plenum Press.

Delcker, J., Heil, J., Ifenthaler, D., Seufert, S., y Spirgi, L. (2024). First-year students' AI-competence as a predictor for intended and de facto use of AI-tools for supporting learning processes in higher education. *International Journal of Educational Technology in Higher Education*, 21, Article 18. <https://doi.org/10.1186/s41239-024-00452-7>

Essel, H. B., Vlachopoulos, D., Tachie-Menson, A., Johnson, E. E., y Baah, P. K. (2022). The impact of a virtual teaching assistant (chatbot) on students' learning in Ghanaian higher education. *International Journal of Educational Technology in Higher Education*, 19, Article 57. <https://doi.org/10.1186/s41239-022-00362-6>

Galarza Ramírez, C. M., Vera Zapata, J. A., Acurio Acurio, M. P., y Vivero Quintero, C. E. (2024). Uso de tecnologías IA en la formación de estudiantes con necesidades especiales en entornos inclusivo. *Serie Científica de la Universidad de las Ciencias Informáticas*, 17(12), 184-209.

Isea Arguelles, J. J., Duque Rodríguez, J. A., Piña Ferrer, L. S., y Atencio González, R. E. (2024). Análisis de la Inteligencia artificial en la transformación de la enseñanza y aprendizaje educativa. *Conrado*, 20(100), 179-185.

Jin, Y., Yan, L., Echeverria, V., Gašević, D., y Martínez-Maldonado, R. (2025). Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. *Computers and Education: Artificial Intelligence*, 8, Article 100348. <https://doi.org/10.1016/j.caeai.2024.100348>

Lancheros-Bohorquez, W. F., y Vesga-Bravo, G. J. (2024). Uso de la realidad aumentada, la realidad virtual y la inteligencia artificial en educación secundaria: una revisión sistemática. *Revista de Investigación, Desarrollo e Innovación*, 14(1), 95-110. <https://doi.org/10.19053/uptc.20278306.v14.n1.2024.17537>

Mah, D. K., y Groß, N. (2024). Artificial intelligence in higher education: Exploring faculty use, self-efficacy, distinct profiles, and professional development needs. *International Journal of Educational Technology in Higher Education*, 21, Article 58. <https://doi.org/10.1186/s41239-024-00490-1>

Martínez Cardero, D. (2024). Innovación pedagógica, aprendizaje significativo y creatividad en la enseñanza de inteligencia artificial para Ingeniería Informática. *Serie Científica de la Universidad de las Ciencias Informáticas*, 17(7), 85-107.

Panqueban, D., y Huincahue, J. (2024). Artificial Intelligence in Mathematics Education: A Systematic Review. *Uniciencia*, 38(1), 357-373. <https://doi.org/10.15359/ru.38-1.20>

Quinde Rosales, V. X., García Estupiñán, S. B., y Tenelanda Mora, D. B. (2024). La Inteligencia Artificial y su utilidad en el campo Académico. Un Análisis desde la perspectiva del Universitario. *Conrado*, 20(99), 187-193.

Rodríguez Ramírez, J., Rodríguez Castilla, L., y Padrón Alvarez, A. (2024). Investigar utilizando la IA como una fuente confiable. Nuevos retos para el docente en la educación superior. *Referencia Pedagógica*, 12(3), 84-98.

Santillán Lima, J. C., Duque Vaca, M. Á., Urgiles Rodríguez, B. E., y Tixi Gallegos, K. G. (2024). Integración de las nuevas tecnologías basadas en inteligencia artificial para la enseñanza de las matemáticas. *Revista Universidad y Sociedad*, 16(6), 228-237.

Sun, D., Ba, S., Cha, Y., Yu, J., Chiang, F.-K., Dai, H. M., y Lim, C.-P. (2026). Empowering university teachers in higher education: A generative AI-responsive competency framework. *Computers and Education: Artificial Intelligence*, 10, Article 100542. <https://doi.org/10.1016/j.caeai.2026.100542>

Sweller, J. (1988). Cognitive load during problem solving: Effects on learning. *Cognitive Science*, 12(2), 257–285. https://doi.org/10.1207/s15516709cog1202_4

Villamar Ponce, J. L., Ponce Merino, S. R., Tumbaco Figueroa, G. P., y Pisco Rodríguez, L. V. (2024). Inteligencia Artificial como catalizador en la motivación y el compromiso académico de estudiantes universitarios. *Serie Científica de la Universidad de las Ciencias Informáticas*, 17(8), 70-85.

Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press.

Xia, Q., Weng, X., Ouyang, F., Lin, T. J., y Chiu, T. K. F. (2024). A scoping review on how generative artificial intelligence transforms assessment in higher education. *International Journal of Educational Technology in Higher Education*, 21, Article 40. <https://doi.org/10.1186/s41239-024-00468-z>

Yusuf, A., Pervin, N., y Román-González, M. (2024). Generative AI and the future of higher education: A threat to academic integrity or reformation? Evidence from multicultural perspectives. *International Journal of Educational Technology in Higher Education*, 21, Article 21. <https://doi.org/10.1186/s41239-024-00453-6>

Zimmerman, B. J. (2000). Attaining self-regulation: A social cognitive perspective. In M. Boekaerts, P. R. Pintrich, y M. Zeidner (Eds.), *Handbook of self-regulation* (pp. 13–39). Academic Press.