

Modelo pedagógico adaptativo para la educación superior en línea con inteligencia artificial generativa: mediación docente, autorregulación y transferencia del aprendizaje

Adaptive Pedagogical Model for Online Higher Education with Generative Artificial Intelligence: Teacher Mediation, Self-Regulation and Learning Transfer

Modello pedagogico adattivo per l'istruzione superiore online con intelligenza artificiale generativa: mediazione docente, autoregolazione e trasferimento dell'apprendimento

Rodrigo José Pazmiño Pérez¹

Email: rjpazmino@uagraria.edu.ec

ORCID: <https://orcid.org/0009-0000-9507-6865>

Jenniffer Gabriela Salinas Sedamanos³

Email: jsalinas@defensoria.gob.ec

ORCID: <https://orcid.org/0000-0001-6679-3494>

Elisa Flor Guamán Troya⁵

Email: fguamant@unemi.edu.ec

ORCID: <https://orcid.org/0009-0005-3898-5161>

Vanessa Vergara Lozano²

Email: vvergara@uagraria.edu.ec

ORCID: <https://orcid.org/0000-0002-0644-5946>

Liliam Stephania Garzón Reyes⁴

Email: lgarzon@uagraria.edu.ec

ORCID: <https://orcid.org/0009-0005-3954-4333>

Correspondencia: Rodrigo José Pazmiño Pérez¹ Email: rjpazmino@uagraria.edu.ec

Artículo de investigación

* **Recibido:** 27-07-2026 * **Aceptado:** 02-09-2026 * **Publicado:** 07-09-2026

1. Universidad Agraria del Ecuador, Guayaquil, Ecuador.
2. Universidad Agraria del Ecuador, Guayaquil, Ecuador.
3. Defensoría Pública de Guayaquil, Ecuador.
4. Universidad Agraria del Ecuador, Guayaquil, Ecuador.
5. Universidad Estatal de Milagro (UNEMI), Milagro, Ecuador.

Resumen

La expansión de la inteligencia artificial generativa (IAG) en la educación superior en línea ha avanzado con mayor rapidez que la capacidad institucional para definir el diseño pedagógico que la sostiene. El objetivo fue construir un modelo pedagógico adaptativo que articule adaptatividad tecnológica, mediación docente, autorregulación del aprendizaje y transferencia, a partir de la evidencia empírica verificable disponible. Se aplicó un diseño no experimental, documental y descriptivo-analítico sobre 25 fuentes comprobables publicadas entre 1992 y 2026: metaanálisis, revisiones sistemáticas, estudios empíricos primarios y marcos normativos internacionales. El análisis de contenido dirigido codificó seis categorías: adaptatividad, mediación docente, autorregulación, transferencia, riesgos cognitivos e integridad, y gobernanza institucional. Los sistemas adaptativos con inteligencia artificial reportan un efecto medio-alto sobre los resultados de aprendizaje ($g = 0,70$), mientras la IAG muestra efectos heterogéneos: $g = 0,392$ sobre resultados generales, $g = 0,851$ sobre pensamiento de orden superior y $g = 0,509$ de la retroalimentación automatizada sobre la autorregulación, con magnitudes menores en las dimensiones conductual y metacognitiva. La evidencia documenta además riesgos: el uso intensivo de herramientas de IA correlaciona negativamente con el pensamiento crítico ($r = -0,68$), con la descarga cognitiva como mecanismo mediador. En Ecuador, el 52 % de los estudiantes encuestados usa ChatGPT con frecuencia y ninguno reporta orientación institucional formal. Se propone el modelo MAP-IAG, con seis componentes, reglas operativas e indicadores verificables. Se concluye que la adaptatividad algorítmica se convierte en aprendizaje transferible únicamente cuando la mediación docente conserva las decisiones pedagógicas y se protege deliberadamente el esfuerzo cognitivo del estudiante.

Palabras clave: inteligencia artificial generativa; aprendizaje adaptativo; autorregulación del aprendizaje; mediación docente; transferencia del aprendizaje.

Abstract

The expansion of generative artificial intelligence (GenAI) in online higher education has outpaced the institutional capacity to define the pedagogical design that supports it. This study aimed to build an adaptive pedagogical model articulating technological adaptivity, teacher mediation, self-regulated learning and transfer, based on the available verifiable empirical evidence. A non-experimental, documentary and descriptive-analytical design was applied to 25 verifiable sources published between 1992 and 2026: meta-analyses, systematic reviews, primary empirical studies and international normative frameworks. Directed content analysis coded six categories: adaptivity, teacher mediation, self-regulation, transfer, cognitive and integrity risks, and institutional governance. AI-enabled adaptive learning systems report a medium-to-large effect on learning outcomes ($g = 0.70$), whereas GenAI shows heterogeneous effects: $g = 0.392$ on general outcomes, $g = 0.851$ on higher-order thinking and $g = 0.509$ for automated feedback on self-regulation, with smaller magnitudes in the behavioural and metacognitive dimensions. Evidence also documents risks: intensive use of AI tools correlates negatively with critical thinking ($r = -0.68$), with cognitive offloading as the mediating mechanism. In Ecuador, 52% of surveyed students frequently use ChatGPT and none report formal institutional guidance. The MAP-IAG model is proposed, with six components, operational rules and auditable indicators. It is concluded that algorithmic adaptivity becomes transferable learning only when teacher mediation retains pedagogical decisions and the student's cognitive effort is deliberately protected.

Keywords: generative artificial intelligence; adaptive learning; self-regulated learning; teacher mediation; learning transfer.

Riassunto

L'espansione dell'intelligenza artificiale generativa (IAG) nell'istruzione superiore online è avanzata più rapidamente della capacità istituzionale di definire il disegno pedagogico che la sostiene. L'obiettivo è stato costruire un modello pedagogico adattivo che articoli adattività tecnologica, mediazione docente, autoregolazione dell'apprendimento e trasferimento, a partire dalle evidenze empiriche verificabili disponibili. È stato applicato un disegno non sperimentale, documentale e descrittivo-analitico su 25 fonti verificabili pubblicate tra il 1992 e il 2026: meta-analisi, revisioni sistematiche, studi empirici primari e quadri normativi internazionali. L'analisi del contenuto ha codificato sei categorie: adattività, mediazione docente, autoregolazione, trasferimento, rischi cognitivi e integrità, governance istituzionale. I sistemi adattivi con intelligenza artificiale riportano un effetto medio-alto sui risultati di apprendimento ($g = 0,70$), mentre l'IAG mostra effetti eterogenei: $g = 0,392$ sui risultati generali, $g = 0,851$ sul pensiero di ordine superiore e $g = 0,509$ del feedback automatizzato sull'autoregolazione, con magnitudini minori nelle dimensioni comportamentale e metacognitiva. Le evidenze documentano inoltre rischi: l'uso intensivo di strumenti di IA correla negativamente con il pensiero critico ($r = -0,68$), con lo scarico cognitivo come meccanismo mediatore. In Ecuador, il 52 % degli studenti intervistati usa frequentemente ChatGPT e nessuno dichiara un orientamento istituzionale formale. Si propone il modello MAP-IAG, con sei componenti, regole operative e indicatori verificabili. Si conclude che l'adattività algoritmica diventa apprendimento trasferibile solo quando la mediazione docente conserva le decisioni pedagogiche e lo sforzo cognitivo dello studente è deliberatamente protetto.

Parole chiave: intelligenza artificiale generativa; apprendimento adattivo; autoregolazione dell'apprendimento; mediazione docente; trasferimento dell'apprendimento.

Introducción

La educación superior en línea concentra hoy dos procesos que avanzan a velocidades distintas. Por un lado, la disponibilidad de modelos generativos de lenguaje convirtió en cotidiana una capacidad que hasta hace poco era experimental: producir explicaciones, resolver ejercicios, redactar y retroalimentar en segundos. Por otro, el diseño instruccional que debería gobernar ese uso continúa anclado en marcos concebidos para entornos virtuales sin agentes capaces de generar contenido. Zawacki-Richter et al. (2019) advirtieron esta asimetría antes de la irrupción de los modelos conversacionales masivos: la investigación sobre inteligencia artificial en educación superior se concentraba en soluciones técnicas y prescindía de la perspectiva pedagógica y de los propios educadores. La brecha no se ha cerrado; se ha vuelto más urgente.

La evidencia acumulada permite hoy afirmaciones más precisas que las de los primeros años de entusiasmo. Los sistemas de aprendizaje adaptativo apoyados en inteligencia artificial muestran un efecto medio-alto sobre los resultados de aprendizaje, con un tamaño de efecto agregado de $g = 0,70$ sobre estudios publicados entre 2010 y 2022, sin que el tipo de algoritmo empleado en el motor adaptativo modere significativamente ese resultado (Wang et al., 2024). El dato es pedagógicamente decisivo: la ganancia no proviene de la sofisticación del modelo, sino del diseño instruccional que lo enmarca. La IAG, en cambio, presenta efectos más modestos y heterogéneos sobre los resultados de aprendizaje ($g = 0,392$), con magnitudes mayores cuando las intervenciones se sostienen en el tiempo (Zhu et al., 2025), y efectos considerables cuando la tarea exige pensamiento de orden superior ($g = 0,851$; Nie et al., 2025). Las revisiones sistemáticas centradas en educación superior reportan resultados mixtos y advierten sobre la dependencia excesiva y la escasez de estudios longitudinales (Hon, 2026).

El segundo eje del problema es la autorregulación. Zimmerman (2002) definió al aprendiz autorregulado como aquel que activa cíclicamente procesos de planificación, monitoreo y autoevaluación para alcanzar metas propias. En entornos en línea, esa capacidad es la variable que más condiciona la persistencia y el desempeño, y es también la que la IAG puede fortalecer o erosionar. La retroalimentación generada por inteligencia artificial produce un efecto medio sobre la autorregulación ($g = 0,509$), pero desigual: mayor en las dimensiones motivacional y cognitiva, y menor precisamente en las dimensiones conductual y metacognitiva, que son las que sostienen la autonomía (Huang et al., 2026). Los estudiantes reconocen que las aplicaciones de inteligencia artificial apoyan la regulación metacognitiva, cognitiva y conductual, pero no perciben apoyo en la dimensión motivacional (Jin et al., 2023), y el apoyo metacognitivo explícito resulta crítico para que los entornos con IAG mejoren la experiencia y la autorregulación (Xu et al., 2025).

El tercer eje es el riesgo cognitivo. Gerlich (2025) documentó, sobre 666 participantes, una correlación negativa entre el uso intensivo de herramientas de inteligencia artificial y el pensamiento crítico ($r = -0,68$) y una correlación positiva con la descarga cognitiva ($r = +0,72$), que opera como mecanismo mediador ($b = -0,25$). Este hallazgo no invalida el uso educativo de la IAG, pero obliga a un principio de diseño ausente en la mayoría de las propuestas: si la herramienta puede realizar la operación cognitiva que el curso busca desarrollar, la arquitectura didáctica debe delimitar cuándo esa operación queda reservada al estudiante. Kasneci et al. (2023) formularon tempranamente esta tensión entre oportunidad y riesgo, y UNESCO (2023) la trasladó al plano normativo al exigir validación ética y diseño pedagógico con supervisión humana antes de la adopción institucional.

El contexto regional agrega una condición ineludible. La revisión sistemática de Blake Angulo (2026) sobre 35 estudios latinoamericanos publicados entre 2023 y 2025 muestra una agenda concentrada en las necesidades de formación docente (54 %) y en la integridad académica (54 %), con escasa atención a la desigualdad tecnológica (17 %) y a las políticas institucionales (20 %). En Ecuador, Mora Torres (2026) reporta que alrededor del 52 % de los estudiantes universitarios encuestados usa ChatGPT con frecuencia, mientras ninguno declara haber recibido orientación institucional formal, en un país donde la tenencia de computador se mantiene en el 32,7 %. La adopción, por tanto, es real, masiva y autodidacta, y ocurre en ausencia de un marco pedagógico explícito.

Conviene precisar por qué las propuestas disponibles resultan insuficientes. La tradición del aprendizaje adaptativo se construyó sobre la personalización del contenido: qué material se entrega, en qué secuencia y con qué nivel de dificultad. Ese enfoque resolvió un problema real —la heterogeneidad de conocimientos previos— pero dejó fuera la pregunta que la IAG vuelve urgente: qué operaciones cognitivas realiza el estudiante y cuáles delega. Cuando un modelo generativo puede producir el ensayo, el código o el análisis que constituían la evidencia de aprendizaje, la personalización del contenido pierde capacidad explicativa y la unidad de adaptación debe desplazarse hacia el proceso regulatorio. Esta es la premisa que organiza el modelo propuesto en este artículo.

El problema de investigación se formula así: ¿qué componentes debe integrar un modelo pedagógico adaptativo para que el uso de IAG en la educación superior en línea produzca aprendizaje autorregulado y transferible, en lugar de sustitución cognitiva? El objetivo fue analizar la evidencia empírica y normativa disponible sobre adaptatividad, mediación docente, autorregulación y transferencia, y derivar de ella un modelo operativo con indicadores verificables. La contribución consiste en integrar en una sola arquitectura tres cuerpos de literatura que suelen discutirse por separado —eficacia de los sistemas adaptativos, regulación híbrida humano-IA y transferencia del aprendizaje— y en traducirlos a decisiones docentes evaluables en contextos con restricciones de conectividad y equipamiento como el ecuatoriano.

Metodología

Se desarrolló una investigación no experimental, documental y de alcance descriptivo-analítico. No se levantaron encuestas, entrevistas ni observaciones primarias: la totalidad de los resultados procede de publicaciones científicas identificables y de documentos normativos de organismos internacionales. La unidad de análisis fue el corpus documental, y la unidad de registro estuvo constituida por afirmaciones, tamaños de efecto y prescripciones de diseño relativos a cuatro constructos: adaptatividad instruccional, mediación docente, autorregulación del aprendizaje y transferencia.

La búsqueda se cerró el 15 de julio de 2026 y se realizó en bases y repositorios de acceso abierto e indexado (Scopus, Web of Science, SciELO, Dialnet, DOAJ y repositorios editoriales), combinando descriptores en español e inglés: «generative artificial intelligence», «adaptive learning», «self-regulated learning», «teacher mediation», «learning transfer», «higher education» y sus equivalentes. El corpus final quedó integrado por 25 fuentes: 4 metaanálisis con síntesis cuantitativa, 5 revisiones sistemáticas o de alcance, 8 estudios empíricos primarios, 2 marcos normativos internacionales y 6 aportes teórico-conceptuales de referencia.

Los criterios de inclusión fueron: publicación entre 2019 y 2026, salvo referentes teóricos fundacionales incorporados por su función conceptual; autoría institucional reconocida o revisión

por pares; relación directa con al menos una de las cuatro categorías analíticas; y disponibilidad de metadatos verificables (DOI o URL oficial). Se excluyeron notas comerciales, textos sin procedencia comprobable, duplicados y trabajos cuyos datos no pudieron contrastarse con la fuente primaria. Se priorizó la evidencia agregada (metaanálisis) sobre la evidencia de estudio único cuando ambas informaban el mismo constructo.

El análisis empleó codificación dirigida en seis categorías: a) adaptatividad y personalización; b) mediación docente y presencia didáctica; c) autorregulación y andamiaje metacognitivo; d) transferencia del aprendizaje; e) riesgos cognitivos, dependencia e integridad académica; y f) gobernanza institucional y competencia digital docente. Los tamaños de efecto se transcribieron tal como los reportan las fuentes, sin recalcularlos ni convertirlos entre métricas, y se registraron junto con el tamaño del corpus y los moderadores informados. Cada afirmación del apartado de resultados se clasificó como dato observado, interpretación documental o propuesta derivada.

La validez se fortaleció mediante triangulación de tres tipos de evidencia: síntesis cuantitativa, estudios primarios y marcos normativos. Las principales limitaciones son la heterogeneidad metodológica de los estudios agregados —expresada, por ejemplo, en el amplio intervalo de predicción reportado por Huang et al. (2026)—, la ausencia de datos primarios de aula recogidos por el autor y la escasez de estudios longitudinales sobre transferencia. En consecuencia, el modelo propuesto constituye un producto analítico de diseño instruccional, no un programa cuya eficacia haya sido medida. Al utilizar exclusivamente información secundaria y no tratar datos personales, el estudio no requirió evaluación ética con participantes humanos.

Resultados

Eficacia diferencial de la adaptatividad y de la inteligencia artificial generativa

La síntesis cuantitativa muestra un patrón consistente: los efectos más altos y estables corresponden a los sistemas adaptativos diseñados instruccionalmente, mientras los efectos de la IAG dependen de la tarea y de la duración de la intervención. Wang et al. (2024) reportan $g = 0,70$ para sistemas adaptativos y, de manera relevante, que el tipo de inteligencia artificial del motor no modera significativamente los resultados; sí lo hacen el nivel del estudiante, la disciplina, la duración y el diseño del estudio. Zhu et al. (2025), sobre 26 estudios seleccionados de 5.887 registros, obtienen un efecto global significativo pero pequeño ($g = 0,392$) e identifican la duración de la intervención como moderador: las implementaciones prolongadas superan a las breves. Nie et al. (2025) encuentran un efecto alto sobre el pensamiento de orden superior ($g = 0,851$), lo que sugiere que el beneficio se concentra allí donde la tarea exige análisis, evaluación y creación, y no en la mera reproducción de contenidos.

Tabla 1. Síntesis de la evidencia cuantitativa sobre adaptatividad, IAG y aprendizaje

Fuente	Corpus analizado	Resultado principal reportado	Implicación para el diseño
Wang et al. (2024)	Sistemas adaptativos con IA, 2010–2022	$g = 0,70$ sobre resultados del aprendizaje; el tipo de IA del motor adaptativo no modera el efecto	La ganancia depende del diseño instruccional, no del algoritmo
Zhu et al. (2025)	26 estudios seleccionados de 5.887 registros	$g = 0,392$ global; $g = 0,372$ en resultados intelectuales; mayor efecto en intervenciones prolongadas	La IAG exige continuidad curricular, no usos episódicos

Fuente	Corpus analizado	Resultado principal reportado	Implicación para el diseño
Nie et al. (2025)	19 estudios; 68 tamaños de efecto; 2.347 participantes	$g = 0,851$ en pensamiento de orden superior (IC 95 % [0,452; 1,250])	El beneficio se concentra en tareas cognitivamente exigentes
Huang et al. (2026)	85 artículos; $k = 387$; $N = 9.564$	$g = 0,509$ de la retroalimentación de IA sobre la autorregulación; menor en las dimensiones conductual y metacognitiva	La retroalimentación automática no sustituye el andamiaje metacognitivo
Suazo-Galdamés y Chaple-Gil (2025)	14 estudios (2013–2025)	Mejoras en desempeño, compromiso, retención y satisfacción; barreras de privacidad, sesgo y disparidad regional	La escalabilidad depende de condiciones institucionales, no solo técnicas
Hon (2026)	Revisión sistemática de estudios 2018–2024	Evidencia mixta; dependencia excesiva; ausencia de estudios longitudinales y a gran escala	Cada institución debe evaluar su propia implementación
Gerlich (2025)	666 participantes	$r = -0,68$ entre uso de IA y pensamiento crítico; $r = +0,72$ con descarga cognitiva; efecto indirecto $b = -0,25$	Justifica delimitar fases de la tarea que se resuelven sin IAG

Nota. Elaboración propia a partir de las fuentes citadas. Los valores se transcriben tal como los reportan los autores; g corresponde a la g de Hedges, k al número de tamaños de efecto y N al número total de participantes. La comparación entre estudios es indicativa: los corpus, las poblaciones y las medidas de resultado no son equivalentes.

El contraste entre la primera y la segunda fila de la Tabla 1 concentra el hallazgo central de este apartado. Un sistema adaptativo bien diseñado, aunque emplee mecanismos algorítmicos simples, produce efectos mayores que una herramienta generativa sofisticada utilizada sin estructura instruccional. La adaptatividad que funciona no es la del modelo, sino la de la secuencia didáctica.

Autorregulación: qué apoya la inteligencia artificial y qué no

La evidencia sobre autorregulación es la más matizada del corpus. Huang et al. (2026), en un metaanálisis de tres niveles sobre 85 artículos ($k = 387$; $N = 9.564$), estiman un efecto medio de la retroalimentación de inteligencia artificial sobre la autorregulación ($g = 0,509$), con efectos mayores en las dimensiones motivacional y cognitiva y menores en la conductual y la metacognitiva. El amplio intervalo de predicción reportado indica heterogeneidad sustantiva: el resultado depende del diseño de la intervención más que de la tecnología. Jin et al. (2023) coinciden desde la perspectiva del estudiante: las aplicaciones de inteligencia artificial son percibidas como útiles para regular procesos metacognitivos, cognitivos y conductuales, pero no para sostener la motivación, y su utilidad varía según la identidad, la actividad y la posición del aprendiz. Xu et al. (2025) muestran que el apoyo metacognitivo explícito es la condición crítica para que los entornos con IAG mejoren la autorregulación y la experiencia de aprendizaje.

Los estudios experimentales moderan cualquier expectativa automática. Fütterer et al. (2026), en un ensayo controlado aleatorizado con 371 estudiantes y seis sesiones de trabajo, encontraron que los estímulos orientados al valor de utilidad mejoraron la percepción de utilidad, pero ninguna de las condiciones con IAG superó significativamente al grupo control en resultados de aprendizaje ni en uso de estrategias. Ng et al. (2024), en un estudio piloto sobre educación científica, documentan potencial y a la vez la necesidad de andamiaje docente. En conjunto, la evidencia sostiene una conclusión operativa: la IAG amplifica la autorregulación cuando el diseño la exige explícitamente, y la deja intacta —o la debilita— cuando se limita a resolver la tarea.

Este resultado dialoga con dos aportes conceptuales. Molenaar (2022) propuso la noción de regulación híbrida humano-IA, en la que el control sobre los procesos de aprendizaje se

distribuye dinámicamente entre el estudiante, el docente y el sistema; Järvelä et al. (2023) extendieron el argumento a la regulación socialmente compartida, señalando que la colaboración con agentes artificiales exige hacer visibles los procesos regulatorios para que puedan ser objeto de decisión humana. Un hallazgo de Huang et al. (2026) merece atención especial por su tensión aparente: la retroalimentación conducida íntegramente por inteligencia artificial produjo efectos mayores que la retroalimentación híbrida humano-IA. La lectura razonable no es prescindir del docente, sino reconocer que la hibridación mal diseñada —retroalimentación duplicada, tardía o contradictoria— degrada el efecto, lo que refuerza la necesidad de delimitar con precisión qué retroalimenta cada agente y en qué momento.

Mediación docente, transferencia y riesgos del uso no regulado

La mediación docente no es un añadido normativo, sino un componente con respaldo teórico y empírico. Garrison et al. (1999) establecieron que la presencia didáctica —diseño, facilitación del discurso e instrucción directa— es la condición que convierte la interacción en indagación crítica en entornos mediados por texto; la irrupción de agentes generativos vuelve esa función más exigente, porque el discurso ya no se produce solo entre humanos. UNESCO (2023) sitúa este principio en el plano de la política pública al exigir procesos de validación ética y diseño pedagógico con supervisión humana, y UNESCO (2024) lo traduce en un marco de quince competencias docentes organizadas en cinco dimensiones y tres niveles de progresión, entre las que figuran el pensamiento centrado en el ser humano y la ética de la inteligencia artificial.

La transferencia constituye el criterio último de valor del modelo. Perkins y Salomon (1992) distinguieron entre transferencia cercana, que opera en contextos semejantes al de aprendizaje, y transferencia lejana, que exige abstracción deliberada; solo la segunda evidencia comprensión disciplinar. Álvarez (2025), en un estudio cualitativo con 27 estudiantes universitarios, mostró que la transferencia se consolida cuando la evaluación es participativa, colaborativa y permite reconocer y discutir el error, condiciones que la calificación automatizada no reproduce por sí sola. La implicación de diseño es directa: si la evaluación final admite ser resuelta por un modelo generativo, no mide transferencia, mide disponibilidad de la herramienta.

Los riesgos completan el cuadro. Gerlich (2025) documenta la asociación negativa entre uso intensivo de herramientas de inteligencia artificial y pensamiento crítico, mediada por la descarga cognitiva; Kasneci et al. (2023) anticiparon la necesidad de alfabetización específica y de salvaguardas frente a sesgos y desinformación; y Gümüş y Kara (2025) ofrecen un instrumento validado que operacionaliza la alfabetización en IAG para el aprendizaje en cuatro dimensiones: análisis de necesidades, competencia de formulación de instrucciones, aprendizaje autónomo y pensamiento crítico. En el plano regional, Acevedo Carrillo et al. (2025) sintetizan 40 artículos latinoamericanos y advierten sobre sesgo algorítmico, privacidad y preparación docente insuficiente; Blake Angulo (2026) documenta el desplazamiento de la agenda hacia lo micropedagógico; y Mora Torres (2026) evidencia, para Ecuador, una adopción estudiantil masiva sin ninguna orientación institucional formal y con una tenencia de computador del 32,7 %, condición que impone diseños operables con conectividad intermitente y dispositivos compartidos.

Modelo pedagógico adaptativo derivado (MAP-IAG)

De la triangulación anterior se deriva un modelo de seis componentes, denominado Modelo Adaptativo Pedagógico con Inteligencia Artificial Generativa (MAP-IAG). Se trata de

una propuesta de diseño instruccional y de medición, no de la descripción de un programa en ejecución. Su premisa organizadora es que la adaptación pedagógicamente válida se define por decisiones docentes explícitas sobre qué se automatiza, qué se protege y cómo se demuestra la transferencia.

Tabla 2. Componentes del modelo MAP-IAG, reglas operativas e indicadores

Componente	Regla operativa	Función de la mediación docente	Indicador verificable
Diagnóstico adaptativo situado	La adaptación se origina en evidencia de desempeño y en metas declaradas por el estudiante, no en la actividad de la herramienta	El docente define el mapa de prerequisites y valida las rutas propuestas	% de estudiantes con ruta diagnosticada y meta declarada por unidad
Andamiaje metacognitivo explícito	Cada tarea con IAG incorpora planificación, monitoreo y autoevaluación registrados por el estudiante	El docente modela el ciclo y retira el andamiaje de forma progresiva	Ciclos de planificación-monitoreo-evaluación documentados por estudiante
Retroalimentación híbrida	La IAG retroalimenta el proceso de forma inmediata; el docente retroalimenta criterio, ética y calidad argumentativa	La decisión evaluativa y la calificación permanecen en el docente	Tiempo de retorno; % de retroalimentaciones automáticas revisadas por el docente
Zona de esfuerzo protegido	Se delimitan fases de la tarea que deben resolverse sin IAG para preservar la elaboración cognitiva	El docente fija el «presupuesto de IA» de cada tarea y lo comunica en la consigna	% de la evaluación resuelta sin asistencia; desempeño en tareas sin IAG
Transferencia por tarea auténtica	La evaluación exige aplicar lo aprendido a un contexto nuevo, con defensa oral o demostración de desempeño	El docente diseña el contexto de transferencia y la rúbrica de desempeño	% de tareas con transferencia lejana; desempeño en la defensa
Trazabilidad, integridad y gobernanza	Se declara el uso de IAG, se conservan los registros y se auditan sesgos, accesibilidad y brechas de acceso	El docente aplica la política institucional y forma en alfabetización en IA	% de trabajos con declaración de uso; incidencias de integridad; brecha de acceso atendida

Nota. Propuesta derivada del análisis documental. Los indicadores deben desagregarse por asignatura, cohorte, modalidad y condición de conectividad, y contrastarse con una línea de base institucional antes de atribuir cambios a la intervención.

La operacionalización didáctica del modelo se organiza en cinco fases dentro de cada unidad de aprendizaje. La secuencia responde a los hallazgos previos: concentra el uso de la IAG en el contraste y la revisión —donde la evidencia muestra mayores efectos sobre el pensamiento de orden superior— y la excluye de la fase de elaboración inicial, que es la que la descarga cognitiva amenaza directamente.

Tabla 3. Operacionalización del modelo en una unidad de aprendizaje en línea

Fase	Actividad del estudiante	Función asignada a la IAG	Evidencia de aprendizaje
1. Activación	Declara metas, conocimientos previos y plan de estudio de la unidad	Diagnóstico conversacional y sugerencia de ruta, validada por el docente	Plan inicial con metas y criterios de éxito
2. Elaboración protegida	Resuelve el núcleo conceptual sin asistencia generativa	Ninguna; se habilita solo consulta de fuentes	Producción propia con registro de proceso
3. Contraste asistido	Somete su producción a crítica, compara alternativas y reformula	Retroalimentación de proceso, contraejemplos y preguntas socráticas	Versión revisada con justificación de cambios

Fase	Actividad del estudiante	Función asignada a la IAG	Evidencia de aprendizaje
4. Mediación docente	Participa en retroalimentación dialogada y ajusta criterios	Síntesis de errores frecuentes para el docente	Retroalimentación docente registrada y respondida
5. Transferencia y defensa	Aplica lo aprendido a un caso nuevo y defiende su solución	Simulación de escenarios alternativos, sin producir la solución	Desempeño en tarea auténtica y defensa oral

Nota. Elaboración propia. La fase 2 constituye la «zona de esfuerzo protegido»; su extensión debe ajustarse al nivel del estudiante y explicitarse en la consigna y en la rúbrica de evaluación.

El modelo incorpora, además, un conjunto explícito de salvaguardas. Cada una responde a un riesgo documentado en el corpus y se asigna a un componente responsable, de modo que la mitigación no dependa de la buena voluntad del docente sino de una decisión de diseño verificable. La Tabla 4 sintetiza esa correspondencia entre riesgo, evidencia y salvaguarda.

Tabla 4. Riesgos documentados y salvaguardas incorporadas al modelo

Riesgo documentado	Evidencia de respaldo	Salvaguarda incorporada al modelo	Componente
Descarga cognitiva y deterioro del pensamiento crítico	Asociación negativa entre uso intensivo de IA y pensamiento crítico, mediada por descarga cognitiva (Gerlich, 2025)	Fases de elaboración resueltas sin asistencia generativa y evaluación de desempeño sin IAG	Zona de esfuerzo protegido
Autonomía aparente sin autorregulación real	Menores efectos de la retroalimentación de IA en las dimensiones metacognitiva y conductual (Huang et al., 2026)	Registro obligatorio del ciclo de planificación, monitoreo y autoevaluación	Andamiaje metacognitivo
Sustitución de la autoría y pérdida de integridad académica	Prioridad de la integridad académica en el 54 % de los estudios latinoamericanos (Blake Angulo, 2026)	Declaración obligatoria del uso de IAG, conservación de versiones y defensa oral	Trazabilidad y gobernanza
Ampliación de la brecha digital	Tenencia de computador del 32,7 % y ausencia de orientación institucional en Ecuador (Mora Torres, 2026)	Diseño operable de forma asincrónica, con herramientas de acceso abierto y evidencias de bajo consumo de datos	Diagnóstico adaptativo situado
Sesgo algorítmico y tratamiento de datos	Advertencias sobre sesgo, privacidad y preparación docente (Acevedo Carrillo et al., 2025; UNESCO, 2023)	Auditoría periódica de sesgos, accesibilidad y decisiones automatizadas con supervisión humana	Trazabilidad y gobernanza
Evaluación que la herramienta puede resolver	La transferencia se consolida en evaluaciones participativas y dialogadas (Álvarez, 2025)	Tareas auténticas en contexto nuevo con defensa de desempeño y rúbrica de transferencia	Transferencia por tarea auténtica

Nota. Elaboración propia a partir de las fuentes citadas. La columna de evidencia remite a hallazgos reportados por los autores; la columna de salvaguarda corresponde a la propuesta derivada del análisis y no ha sido sometida a validación empírica.

Discusión

El hallazgo central es que la eficacia atribuida a la inteligencia artificial en educación superior corresponde, en rigor, a la calidad del diseño instruccional que la enmarca. El resultado de Wang et al. (2024) —según el cual el tipo de inteligencia artificial del motor adaptativo no modera el efecto— desplaza la discusión desde la elección de herramienta hacia la arquitectura pedagógica. Esto explica la aparente contradicción entre el efecto medio-alto de los sistemas

adaptativos y el efecto pequeño de la IAG en resultados generales (Zhu et al., 2025): los primeros se implementan dentro de secuencias instruccionales con objetivos, diagnóstico y progresión; la segunda se introduce, con frecuencia, como herramienta libre sobre tareas no rediseñadas.

El modelo propuesto se distingue de las aproximaciones centradas en la personalización de contenidos porque su unidad de adaptación no es el material, sino el proceso regulatorio. Esta decisión se apoya en la evidencia de que la retroalimentación automatizada produce efectos menores precisamente en las dimensiones metacognitiva y conductual (Huang et al., 2026) y en que los estudiantes no perciben apoyo motivacional en estas aplicaciones (Jin et al., 2023). Si el sistema adapta el contenido pero no exige planificación, monitoreo ni autoevaluación, optimiza la eficiencia de la respuesta y no la capacidad de aprender. La incorporación del andamiaje metacognitivo explícito como componente obligatorio traduce el hallazgo de Xu et al. (2025) en una regla de diseño verificable.

La «zona de esfuerzo protegido» constituye el componente más discutible y, a la vez, el más necesario. Su justificación es doble: la asociación entre uso intensivo de IA, descarga cognitiva y deterioro del pensamiento crítico documentada por Gerlich (2025), y el hecho de que los efectos positivos de la IAG se concentran en tareas de orden superior (Nie et al., 2025), que presuponen una elaboración previa que el estudiante debe haber realizado. Conviene señalar dos límites de esta interpretación. Primero, el estudio de Gerlich es correlacional y no permite establecer causalidad; segundo, su muestra no es específicamente universitaria. La regla, por tanto, se propone como principio precautorio sustentado en teoría del aprendizaje, no como consecuencia demostrada.

La tensión más productiva del corpus es el hallazgo de que la retroalimentación conducida por inteligencia artificial superó a la híbrida humano-IA (Huang et al., 2026). Interpretarlo como argumento para reducir la intervención docente sería un error de lectura: los estudios agregados comparan condiciones de retroalimentación, no modelos de gobernanza pedagógica, y no incorporan la transferencia lejana ni la integridad como variables de resultado. La lectura defendible es que la mediación docente debe reorganizarse: no competir con la retroalimentación inmediata de proceso, en la que el sistema es más eficiente, sino concentrarse en criterio disciplinar, evaluación de la transferencia, discusión del error y decisiones éticas, funciones que corresponden a la presencia didáctica descrita por Garrison et al. (1999) y a las competencias del marco de UNESCO (2024).

Para el contexto ecuatoriano, la implicación es de política institucional antes que de innovación tecnológica. Con un 52 % de estudiantes usando ChatGPT de forma frecuente y ninguno reportando orientación formal (Mora Torres, 2026), el vacío no es de acceso a la herramienta, sino de reglas de uso, criterios de evaluación y formación docente. La concentración de la investigación regional en formación docente e integridad académica (Blake Angulo, 2026) confirma que estas son las dos capacidades críticas. En condiciones de tenencia de computador del 32,7 %, además, cualquier modelo que presuponga sesiones sincrónicas intensivas o herramientas de pago reproduce la desigualdad que dice combatir: de ahí que los componentes del MAP-IAG se hayan formulado para ser implementables con recursos de acceso abierto y evidencias asincrónicas.

En el plano de la práctica docente, la implicación más concreta afecta a la rúbrica. Si la evaluación conserva criterios formulados para productos escritos convencionales —extensión, corrección formal, cobertura temática—, un modelo generativo los satisface sin que exista

aprendizaje. El rediseño exige criterios que la herramienta no puede cumplir por el estudiante: justificación de las decisiones adoptadas, identificación y corrección del error propio, adaptación de la solución a restricciones del contexto y desempeño en la defensa. En asignaturas de programación, por ejemplo, esto se traduce en evaluar la depuración de un programa que falla, la explicación de la complejidad de la solución y la modificación de requisitos en tiempo real, antes que la producción de código funcional, que es precisamente la tarea que la IAG resuelve con mayor solvencia. La alfabetización en IAG, operacionalizada por Gümüş y Kara (2025) en análisis de necesidades, formulación de instrucciones, aprendizaje autónomo y pensamiento crítico, ofrece un referente para incorporar esas competencias como objeto explícito de enseñanza y no como supuesto.

El estudio tiene límites que condicionan sus conclusiones. Los tamaños de efecto provienen de corpus heterogéneos, con poblaciones y medidas no equivalentes, por lo que su comparación es indicativa y no sustituye una síntesis cuantitativa propia. La literatura disponible sobre transferencia en entornos con IAG es todavía escasa y predominantemente cualitativa (Álvarez, 2025), y la evidencia longitudinal es prácticamente inexistente (Hon, 2026). El modelo no ha sido sometido a validación empírica: sus indicadores son verificables por construcción, pero su capacidad predictiva permanece sin comprobar. La agenda inmediata consiste en pilotar el MAP-IAG en asignaturas de programación y de posgrado, con diseño cuasiexperimental, medición pre-post de estrategias de autorregulación y evaluación de transferencia mediante tareas auténticas y defensa oral.

Implicaciones para la política institucional

Trasladar el modelo a una institución exige distribuir sus exigencias entre niveles de decisión, porque ninguno de sus componentes se sostiene únicamente en el aula. La política de uso, la formación docente, el rediseño evaluativo y la auditoría de datos corresponden a instancias distintas, y su desalineación explica buena parte del vacío que documentan los estudios regionales. La Tabla 5 organiza esa distribución y vincula cada acción con la evidencia que la respalda y con un indicador de cumplimiento observable.

Tabla 5. Hoja de ruta institucional por niveles de decisión

Nivel de decisión	Acción mínima exigible	Evidencia que la respalda	Indicador de cumplimiento
Vicerrectorado académico	Política institucional de uso de IAG con supervisión humana de las decisiones que afectan la calificación	UNESCO (2023) exige validación ética y supervisión humana previa a la adopción	Política aprobada, publicada y vigente; casos revisados por instancia humana
Aseguramiento de la calidad	Rediseño de los criterios de evaluación hacia tareas de transferencia con defensa de desempeño	La transferencia se consolida en evaluaciones participativas y dialogadas (Álvarez, 2025)	% de asignaturas con evaluación de transferencia auditada
Coordinación de carrera	Formación docente en competencias de inteligencia artificial y en rediseño de consignas	Necesidades de formación docente en el 54 % de los estudios latinoamericanos (Blake Angulo, 2026); marco de competencias de UNESCO (2024)	Docentes formados por nivel de progresión del marco

Nivel de decisión	Acción mínima exigible	Evidencia que la respalda	Indicador de cumplimiento
Docencia	Consigna que declara el «presupuesto de IA» de cada tarea y exige declaración de uso	La descarga cognitiva media el deterioro del pensamiento crítico (Gerlich, 2025)	% de consignas con presupuesto de IA explícito
Unidad de tecnología y datos	Auditoría de accesibilidad, sesgos y tratamiento de datos; provisión de alternativas de bajo consumo	Advertencias sobre sesgo y privacidad (Acevedo Carrillo et al., 2025); tenencia de computador del 32,7 % (Mora Torres, 2026)	Auditoría anual publicada; brecha de acceso medida y atendida
Investigación institucional	Línea de base y evaluación longitudinal de los indicadores del modelo	Ausencia de estudios longitudinales y a gran escala (Hon, 2026)	Informe anual con series comparables por cohorte

Nota. Elaboración propia. Las acciones se formulan como mínimos exigibles y no como estándares de excelencia; su verificación anual debería documentarse en el informe institucional de calidad.

Tres advertencias acompañan esta hoja de ruta. La primera es de secuencia: la política de uso y la formación docente deben preceder a la exigencia de rediseño evaluativo, porque pedir a un docente que evalúe transferencia sin haberle dado criterios ni tiempo de rediseño produce cumplimiento formal y no cambio pedagógico. La segunda es de proporcionalidad: en instituciones con restricciones de equipamiento, la auditoría de accesibilidad debe anteceder a cualquier requisito que presuponga acceso permanente a herramientas de pago, para no convertir una política de calidad en un mecanismo de exclusión. La tercera es de evaluación: sin línea de base, cualquier mejora posterior será atribuible a múltiples causas, de modo que el levantamiento inicial de indicadores constituye la primera acción, no la última.

La adopción de este esquema no supone que la evidencia disponible respalde cada una de sus acciones con la misma solidez. Las relativas a supervisión humana, formación docente y transparencia se apoyan en marcos normativos y en revisiones que las identifican como necesidades reiteradas; las relativas a la evaluación de transferencia y a los indicadores de autorregulación se apoyan en evidencia empírica todavía limitada y mayoritariamente ajena al contexto ecuatoriano. Reconocer esa asimetría es parte del rigor de la propuesta: la hoja de ruta se ofrece como hipótesis institucional verificable, sujeta a revisión conforme los pilotos generen datos propios.

Conclusiones

La evidencia disponible no sostiene la expectativa de que la incorporación de inteligencia artificial generativa mejore por sí sola el aprendizaje en la educación superior en línea. Sostiene algo más exigente y más útil: que los efectos dependen del diseño instruccional, de la duración de la intervención y del tipo de tarea, y que el aporte se concentra en actividades que demandan pensamiento de orden superior. La adaptatividad que produce resultados es pedagógica antes que algorítmica.

La autorregulación constituye el mecanismo que explica ese resultado. La retroalimentación automatizada muestra un efecto medio sobre la autorregulación, pero desigual entre dimensiones, con menor impacto justamente en la metacognitiva y la conductual. Por ello, un modelo que aspire a producir autonomía debe incorporar el andamiaje metacognitivo como componente obligatorio y verificable, y no confiarlo a la interacción espontánea con la herramienta.

El modelo MAP-IAG articula seis componentes —diagnóstico adaptativo situado, andamiaje metacognitivo explícito, retroalimentación híbrida, zona de esfuerzo protegido, transferencia por tarea auténtica y trazabilidad con gobernanza— y los traduce a indicadores verificables. Su premisa es que la decisión sobre qué se automatiza y qué se protege es una decisión docente, no una configuración técnica, y que debe explicitarse en la consigna, la rúbrica y la política institucional.

La transferencia opera como criterio de validez del conjunto. Una evaluación que un modelo generativo puede resolver íntegramente no informa sobre el aprendizaje del estudiante; en cambio, las tareas auténticas con defensa de desempeño, en contextos distintos al de instrucción, permiten distinguir entre disponibilidad de herramienta y comprensión disciplinar. Esta distinción debería orientar el rediseño de los sistemas de evaluación en línea antes que la adquisición de nuevas plataformas.

Para el sistema de educación superior ecuatoriano, la conclusión es que la prioridad no es tecnológica sino institucional: formación docente en competencias de inteligencia artificial, reglas explícitas de uso y declaración, evaluación centrada en transferencia y atención a las brechas de equipamiento y conectividad. La implementación del modelo debería iniciarse mediante pilotos por asignatura, con evaluación anual pública y posibilidad de rediseño cuando los indicadores muestren dependencia, deterioro del desempeño sin asistencia o ampliación de las brechas de acceso.

Referencias

- Acevedo Carrillo, M., Cabezas Torres, N. M., La Serna La Rosa, P. A., & Araujo Rossel, S. A. (2025). Desafíos y oportunidades de la inteligencia artificial en la educación superior latinoamericana: una revisión sistemática de la literatura. *Revista InveCom*, 6(1), 1–10. <https://doi.org/10.5281/zenodo.15508755>
- Álvarez, M. (2025). Transferencia de aprendizajes estudiantiles en educación superior desde procesos de evaluación transformacionales, participativos y colaborativos. *European Public & Social Innovation Review*, 10, 1–14. <https://doi.org/10.31637/epsir-2025-1751>
- Blake Angulo, J. (2026). Docencia e inteligencia artificial generativa en educación superior en América Latina: focos y vacíos de la investigación emergente (revisión sistemática 2023-2025). *Revista Realidad Educativa*, 6(1), 153–189. <https://doi.org/10.38123/rre.v6i1.600>
- Fütterer, T., Bardach, L., Kuhn, J., Keller, S. D., & Gerjets, P. (2026). Enhancing school students' self-regulated learning through generative AI support: A randomized controlled trial. *Educational Psychology Review*, 38(1), 42. <https://doi.org/10.1007/s10648-026-10133-8>
- Garrison, D. R., Anderson, T., & Archer, W. (1999). Critical inquiry in a text-based environment: Computer conferencing in higher education. *The Internet and Higher Education*, 2(2–3), 87–105. [https://doi.org/10.1016/S1096-7516\(00\)00016-6](https://doi.org/10.1016/S1096-7516(00)00016-6)
- Gerlich, M. (2025). AI tools in society: Impacts on cognitive offloading and the future of critical thinking. *Societies*, 15(1), 6. <https://doi.org/10.3390/soc15010006>
- Gümüş, M. M., & Kara, M. (2025). Development and validation of the Generative AI Literacy for Learning Scale (GenAI-LLs). *Australasian Journal of Educational Technology*, 41(4), 1–16. <https://doi.org/10.14742/ajet.10236>
- Hon, K. L. (2026). Generative AI in higher education: A systematic review of its effects on learning outcomes and academic performance. *Journal of Educational Technology Systems*, 54(3), 537–560. <https://doi.org/10.1177/00472395251400089>
- Huang, C.-Q., Lu, L.-N., Huang, Q.-H., Zhang, Y.-R., He, T., Tu, Y.-F., & Hwang, G.-J. (2026). Effects of artificial intelligence feedback on students' self-regulated learning in higher education: A three-level

- meta-analysis. *Educational Psychology Review*, 38(1), 64. <https://doi.org/10.1007/s10648-026-10166-z>
- Järvelä, S., Nguyen, A., & Hadwin, A. (2023). Human and artificial intelligence collaboration for socially shared regulation in learning. *British Journal of Educational Technology*, 54(5), 1057–1076. <https://doi.org/10.1111/bjet.13325>
- Jin, S.-H., Im, K., Yoo, M., Roll, I., & Seo, K. (2023). Supporting students' self-regulated learning in online learning using artificial intelligence applications. *International Journal of Educational Technology in Higher Education*, 20, 37. <https://doi.org/10.1186/s41239-023-00406-5>
- 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., ... 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>
- Molenaar, I. (2022). The concept of hybrid human-AI regulation: Exemplifying how to support young learners' self-regulated learning. *Computers and Education: Artificial Intelligence*, 3, 100070. <https://doi.org/10.1016/j.caeai.2022.100070>
- Mora Torres, C. E. (2026). Adopción de inteligencia artificial generativa en la educación superior ecuatoriana: evidencia empírica, brechas digitales y desafíos de gobernanza (2024–2025). *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, 7(1), 2839–2856. <https://doi.org/10.56712/latam.v7i1.5479>
- Ng, D. T. K., Tan, C. W., & Leung, J. K. L. (2024). Empowering student self-regulated learning and science education through ChatGPT: A pioneering pilot study. *British Journal of Educational Technology*, 55(4), 1328–1353. <https://doi.org/10.1111/bjet.13454>
- Nie, X., Tian, Y., Liu, M., Wu, D., & Guo, Y. (2025). The impact of generative artificial intelligence on students' higher order thinking: Evidence from a three-level meta-analysis. *Education and Information Technologies*, 30(17), 25359–25390. <https://doi.org/10.1007/s10639-025-13735-x>
- Perkins, D. N., & Salomon, G. (1992). Transfer of learning. En T. Husén & T. N. Postlethwaite (Eds.), *The International Encyclopedia of Education* (2.^a ed., pp. 425–441). Pergamon Press.
- Suazo-Galdamés, I. C., & Chaple-Gil, A. M. (2025). AI-powered adaptive learning systems in higher education: A scoping review of implementation and impact on academic performance. *Data and Metadata*, 4, 981. <https://doi.org/10.56294/dm2025981>
- UNESCO. (2023). Guidance for generative AI in education and research. <https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research>
- UNESCO. (2024). AI competency framework for teachers. <https://www.unesco.org/en/articles/ai-competency-framework-teachers>
- Wang, X., Huang, R. T., Sommer, M., Pei, B., Shidfar, P., Rehman, M. S., Ritzhaupt, A. D., & Martin, F. (2024). The efficacy of artificial intelligence-enabled adaptive learning systems from 2010 to 2022 on learner outcomes: A meta-analysis. *Journal of Educational Computing Research*, 62(6), 1348–1383. <https://doi.org/10.1177/07356331241240459>
- Xu, X., Qiao, L., Cheng, N., Liu, H., & Zhao, W. (2025). Enhancing self-regulated learning and learning experience in generative AI environments: The critical role of metacognitive support. *British Journal of Educational Technology*, 56(5), 1842–1863. <https://doi.org/10.1111/bjet.13599>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & 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, 39. <https://doi.org/10.1186/s41239-019-0171-0>
- Zhu, Y., Liu, Q., & Zhao, L. (2025). Exploring the impact of generative artificial intelligence on students' learning outcomes: A meta-analysis. *Education and Information Technologies*, 30(11), 16211–16239. <https://doi.org/10.1007/s10639-025-13420-z>
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), 64–70. https://doi.org/10.1207/s15430421tip4102_2