



RETROALIMENTACIÓN ADAPTATIVA BASADA EN INTELIGENCIA ARTIFICIAL EN ENTORNOS EDUCATIVOS VIRTUALES: UNA REVISIÓN DE LITERATURA

Vanessa Katherine Guevara Balarezo¹
Rodrigo Cadena Martínez²
ORCID: 0000-0001-9323-6132.

¹ Universidad Americana de Europa (UNAE), Doctorante en Informática, vanessa.guevara@unade.edu.mx.

² Universidad Americana de Europa (UNAE), Profesor Departamento de Informática UNAE, rodrigo.cadena@unade.edu.mx

RESUMEN

La educación superior enfrentó el desafío de ofrecer procesos de enseñanza personalizados en entornos virtuales cada vez más diversos y masivos. Las estrategias tradicionales de retroalimentación, centradas en correcciones manuales o reglas fijas, resultaron insuficientes para atender las necesidades individuales de los estudiantes. En este contexto, la inteligencia artificial (IA) emergió como una alternativa que posibilitó la generación de retroalimentación automatizada, contextualizada y en tiempo real, mejorando la calidad del aprendizaje y la sostenibilidad pedagógica. El objetivo general de este estudio fue analizar la literatura científica publicada entre 2020 y 2025 sobre la aplicación de la IA en la generación de retroalimentación adaptativa en entornos educativos virtuales. Para ello, se adoptó una metodología de revisión sistemática de literatura siguiendo el protocolo PRISMA, a partir de búsquedas en la base de datos Scopus, identificándose 21 estudios que cumplieron con los criterios de inclusión. Los resultados evidenciaron una creciente integración de modelos de aprendizaje automático, procesamiento de lenguaje natural y modelos generativos para ofrecer retroalimentación inmediata, personalizada y escalable. En términos pedagógicos, estos sistemas se asociaron con mejoras en la motivación, la metacognición y el desempeño académico, especialmente cuando el feedback fue específico, oportuno y basado en datos del aprendizaje. En consecuencia, se concluyó que la IA transformó la retroalimentación formativa al potenciar la autonomía, la motivación y la retención del estudiante. No obstante, persistieron desafíos asociados a la calidad de los datos, la dependencia tecnológica y la ética algorítmica. Se identificaron oportunidades en la integración de modelos explicables, multimodales y multilingües para una educación virtual más equitativa e inclusiva.

Palabras clave: Entornos Educativos Virtuales, Inteligencia Artificial, Retroalimentación Adaptativa

ABSTRACT

Higher education faced the challenge of providing personalized teaching processes in increasingly diverse and large-scale virtual environments. Traditional feedback strategies, focused on manual corrections or fixed rules, proved insufficient to address the individual needs of students. In this context, artificial intelligence (AI) emerged as an alternative that enabled the generation of automated, contextualized, and real-time feedback, improving learning quality and pedagogical sustainability. The main objective of this study was to analyze the scientific literature published between 2020 and 2025 on the application of AI in the generation of adaptive feedback in virtual educational environments. To this end, a systematic literature review methodology was adopted following the PRISMA protocol, based on searches in the Scopus database, identifying 21 studies that met the inclusion criteria. The results revealed a growing integration of machine learning models, natural language processing, and generative models to provide immediate, personalized, and scalable feedback. From a pedagogical perspective, these systems were associated with improvements in motivation, metacognition, and academic performance, especially when feedback was specific, timely, and based on learning data. Consequently, it was concluded that AI transformed formative feedback by enhancing student autonomy, motivation, and retention. However, challenges related to data quality, technological dependence, and algorithmic ethics persisted. Opportunities were identified in the integration of explainable, multimodal, and multilingual models to promote more equitable and inclusive virtual education.

Keywords: Artificial Intelligence, Adaptive Feedback, Virtual Learning Environments

INTRODUCCIÓN

La educación superior enfrenta el desafío de personalizar los procesos de enseñanza y aprendizaje en entornos virtuales de aprendizaje (EVA) que crecen de forma sostenida. La diversidad de estilos, ritmos y necesidades estudiantiles exige sistemas capaces de ofrecer retroalimentación formativa oportuna, contextualizada y a escala. Las prácticas tradicionales, basadas en correcciones manuales o reglas fijas, resultan insuficientes para lograr dicha personalización con inmediatez y consistencia.

La inteligencia artificial se presenta como un medio prometedor para generar retroalimentación automatizada, personalizada y en tiempo real. Tecnologías como el aprendizaje automático, el procesamiento del lenguaje natural, los sistemas tutores inteligentes y la analítica de aprendizaje permiten adaptar los comentarios formativos al desempeño, estilo y necesidades de cada estudiante. El periodo 2020–2025 resulta especialmente pertinente por la maduración de los modelos de lenguaje de gran escala y la expansión global de modalidades en línea e híbridas, lo que demanda una síntesis crítica que integre tecnologías, resultados y retos de implementación.

El objetivo general de esta revisión es analizar la literatura científica publicada entre 2020 y 2025 sobre el uso de IA para la retroalimentación adaptativa en EVAs. A partir de este objetivo, se formulan los siguientes objetivos específicos:

- Describir las tecnologías y algoritmos de IA más empleados en sistemas de retroalimentación adaptativa en línea.
- Determinar los principales desafíos asociados con su implementación en contextos educativos virtuales.
- Explorar las oportunidades y las líneas de investigación futuras en retroalimentación adaptativa con IA.

Esta revisión se orienta por la siguiente pregunta de investigación: *¿Cuáles son las principales estrategias y tecnologías de IA utilizadas para generar retroalimentación adaptativa en entornos educativos virtuales, y qué desafíos y oportunidades se identifican en su implementación?*

ESTADO DEL ARTE

La retroalimentación adaptativa constituye un elemento central en los procesos de aprendizaje, ya que facilita que los estudiantes identifiquen la brecha entre su desempeño actual y los objetivos esperados y avancen mediante orientaciones específicas y oportunas. La literatura publicada entre 2020 y 2025 evidencia un campo en rápida evolución, que abarca desde enfoques multimodales y estrategias de gamificación hasta arquitecturas basadas en modelos generativos de lenguaje.

Los estudios recientes se agrupan en tres tendencias principales. La primera corresponde a enfoques centrados en la interacción y el diseño del feedback, donde se integran recursos multimodales y estrategias motivacionales que mejoran la claridad y la participación del estudiante (Renzella & Cain, 2020; Nabil et al., 2021).

La segunda tendencia se relaciona con sistemas predictivos y analítica de aprendizaje, orientados a generar retroalimentación correctiva o preventiva a partir de datos de interacción. En esta línea, se aplican técnicas de minería de datos y modelos de predicción temprana para identificar dificultades y apoyar la intervención docente (Eitemüller et al., 2023; Santos & Henriques, 2023).

La tercera tendencia se centra en el uso de modelos de lenguaje de gran escala y sistemas generativos para producir retroalimentación conversacional y metacognitiva, orientada al desarrollo de la autorregulación (Nakanishi, 2023; Gubelmann et al., 2024; Batita et al., 2024). Asimismo, investigaciones recientes exploran la personalización de cursos a gran escala y el escalamiento de tutores inteligentes mediante inteligencia artificial generativa (Roodsari et al., 2025; Almetnawy et al., 2025; Oubagine et al., 2025; Van Campenhout et al., 2025; Bao & Binh, 2025).

Estas tendencias muestran una transición desde modelos correctivos centrados en la predicción del desempeño hacia enfoques formativos, conversacionales y escalables basados en inteligencia artificial.

MARCO TEÓRICO

La retroalimentación adaptativa se sustenta en principios pedagógicos asociados al aprendizaje autorregulado y al enfoque sociocultural del aprendizaje, los cuales permiten interpretar el papel de la inteligencia artificial como mediadora de procesos formativos.

Desde la teoría del aprendizaje autorregulado, Zimmerman plantea que el estudiante participa activamente en su aprendizaje mediante ciclos de planificación, monitoreo y evaluación. En este proceso, la retroalimentación reduce la brecha entre el desempeño actual y el esperado, ya que proporciona información para ajustar estrategias, corregir errores y fortalecer la autonomía.

En entornos virtuales, los sistemas de retroalimentación adaptativa basados en inteligencia artificial facilitan este proceso al ofrecer feedback inmediato, específico y personalizado, favoreciendo el monitoreo continuo del desempeño y el desarrollo de habilidades metacognitivas.

Por otro lado, el enfoque sociocultural de Vygotsky concibe el aprendizaje como un proceso mediado socialmente, en el cual el estudiante progresa mediante el andamiaje dentro de la Zona de Desarrollo Próximo. En este sentido, la retroalimentación actúa como una guía que permite avanzar hacia niveles superiores de dominio.

Los sistemas conversacionales y generativos basados en inteligencia artificial pueden interpretarse como formas de andamiaje digital, al proporcionar explicaciones, orientaciones y preguntas guiadas durante la resolución de tareas. De este modo, la inteligencia artificial actúa como mediadora cognitiva que amplía las oportunidades de interacción formativa y personalización del aprendizaje.

METODOLOGÍA

Este estudio se desarrolló mediante un enfoque cualitativo, adoptando el diseño de una revisión sistemática de literatura. El objetivo fue sintetizar la evidencia existente sobre la retroalimentación adaptativa basada en inteligencia artificial en entornos educativos virtuales, sin realizar experimentación propia ni generación de datos primarios.

Para garantizar la transparencia y replicabilidad del proceso, se siguieron las directrices del protocolo PRISMA, aplicando criterios sistemáticos de búsqueda, selección y análisis de los estudios incluidos. La búsqueda bibliográfica se realizó en la base de datos Scopus, seleccionada por su amplia cobertura de literatura científica revisada por pares. Se utilizó la siguiente cadena de búsqueda avanzada:

TITLE-ABS-KEY(("adaptive feedback" OR "personalized feedback" OR "formative feedback") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "natural language processing" OR "large language model" OR "intelligent tutoring system*") AND ("online learning" OR "e-learning" OR "virtual learning environment*" OR "learning management system*" OR "MOOC*" OR "digital education"))*

La búsqueda se restringió a publicaciones aparecidas entre el 1 de enero de 2020 y el 31 de agosto de 2025. Este marco temporal se estableció con el propósito de asegurar la actualidad y relevancia de la evidencia en un campo tecnológico que experimenta una rápida evolución.

Para la selección de los estudios de la muestra definitiva, se aplicaron los siguientes criterios de inclusión:

- **Tiempo:** Publicaciones entre el 2020 y el 2025
- **Tipo de Publicación:** Artículos de investigación originales, revisiones sistemáticas, ponencias de conferencias con revisión de pares y capítulos de libro que presentaran resultados empíricos o teóricos relevantes.
- **Idioma:** Se consideraron publicaciones escritas en inglés o español.
- **Disponibilidad:** Se requería que los artículos contaran con texto completo accesible a través de Scopus o mediante acceso institucional.

El proceso de selección se realizó en dos fases, con el apoyo de la herramienta Cadima para la gestión de referencias, eliminación de duplicados y aplicación sistemática de los criterios de elegibilidad.

Cribado por Título y Resumen (Abstract):

Los títulos y resúmenes de los artículos identificados en la búsqueda inicial fueron sometidos a revisión. Se verificó que cada estudio se centrara explícitamente en la retroalimentación adaptativa mediada por IA en entornos educativos virtuales. Los estudios que no satisfacían este criterio fundamental fueron excluidos, con los siguientes criterios:

- Estudios que no poseían un enfoque temático específico.
- Trabajos enfocados en otras funciones de la IA en educación
- Investigaciones no desarrolladas en entornos educativos virtuales.
- Tipos de publicación no académica.
- Estudios que resultaron ser duplicados o que no estaban disponibles en texto completo.


Evaluación de Texto Completo

Los estudios que superaron la etapa inicial fueron recuperados en su formato de texto completo. Se procedió a una lectura para analizar en profundidad su pertinencia temática, la metodología reportada y la disponibilidad del artículo, aplicando de manera definitiva los criterios de inclusión y exclusión.

La búsqueda inicial generó 40 artículos. Tras la eliminación de duplicados y la subsiguiente aplicación de los criterios de exclusión en la fase de cribado, se seleccionaron 22 artículos para la revisión de texto completo. De este conjunto, 21 artículos fueron finalmente incluidos en el análisis cualitativo, dado que un artículo no aportaba significativamente a la pregunta de investigación. El diagrama PRISMA presentado en la Figura 1 sintetiza el proceso de identificación, cribado, elegibilidad e inclusión de los estudios, permitiendo visualizar de forma compacta el flujo de selección de la evidencia analizada.

Figura 1

Diagrama de Flujo PRISMA para selección de estudios



Nota. Se identificaron 40 registros en Scopus; tras el cribado de título y resumen se excluyeron 18 por no cumplir el enfoque temático. De los 22 artículos revisados en texto completo, 1 fue excluido por no cumplir criterios de inclusión, quedando 21 artículos incluidos en la revisión sistemática.

RESULTADOS

La revisión incluye 21 estudios que cumplen los criterios de inclusión definidos en la metodología. En conjunto, los estudios reportan una diversidad de tecnologías de IA aplicadas a la retroalimentación adaptativa, que abarcan: (a) modelos de lenguaje de gran escala como GPT/ChatGPT y Yuanbao (Bauer et al., 2025; Li et al., 2025; Morales-Chan et al., 2024; Naseer & Khawaja, 2025; Naz & Robertson, 2024; Sappa, 2025; Wang et al., 2025); (b) aprendizaje profundo y modelos secuenciales/predictivos (Adnan et


al., 2021; Wang et al., 2022); (c) modelos supervisados y enfoques ensemble/stacking (Qadir et al., 2025); (d) modelos de PLN basados en BERT para similitud semántica y recuperación de evidencia (Araujo et al., 2025); (e) enfoques explicables para predicción e interpretación de rendimiento (Adnan et al., 2022; Embarak, 2025); y (f) tecnologías de soporte multimodal o de infraestructura para práctica remota, visualización y analítica multimodal (Embarak, 2025; Garefalakis et al., 2025; Li et al., 2025; Sharif et al., 2025).

En cuanto a las funciones de la retroalimentación adaptativa, los estudios describen: retroalimentación inmediata/correctiva en tareas estructuradas (Colliot et al., 2024; Eitemüller et al., 2023); predicción temprana del desempeño y emisión de alertas o mensajes de apoyo (Adnan et al., 2021; Adnan et al., 2022; Wang et al., 2022); personalización de contenidos o actividades según perfil o estilo (Wang et al., 2025); retroalimentación dialogada, explicativa o metacognitiva en tareas abiertas (Li et al., 2025; Naz & Robertson, 2024); y retroalimentación escalable basada en rúbricas en contextos masivos (Morales-Chan et al., 2024; Sappa, 2025).

La Figura 2 presenta una síntesis analítica de la relación entre las tecnologías de inteligencia artificial identificadas y las funciones de retroalimentación adaptativa descritas en los estudios revisados, permitiendo observar patrones generales sin recurrir a descripciones individuales.

Figura 2

Mapa de tecnologías versus funciones de retroalimentación adaptativa.



Nota: La figura sintetiza la relación entre las principales tecnologías de IA y las funciones de feedback identificadas en los estudios revisados.

Las métricas de desempeño reportadas incluyen resultados de clasificación/predicción y medidas de calidad o aceptación del feedback. Por ejemplo, se reportan exactitudes cercanas a 0.76 – 0.92 en modelos predictivos y/o de clasificación en LMS/VLE (Adnan et al., 2022; Qadir et al., 2025; Wang et al., 2022) y valores elevados en indicadores de recuperación o pertinencia semántica en PLN (Araujo et al., 2025). En contextos MOOC, se reportan tiempos de respuesta promedio cercanos a 1.8 s y evaluaciones altas de calidad del feedback en modelos más avanzados (Sappa, 2025).

En términos pedagógicos, varios estudios informan mejoras en el desempeño y la transferencia en tareas estructuradas (Colliot et al., 2024; Eitemüller et al., 2023), incrementos en el engagement y la retención (Naseer & Khawaja, 2025; Wang et al., 2022), y avances en procesos metacognitivos cuando se emplea retroalimentación adaptativa basada en inteligencia artificial (Li et al., 2025). Sin embargo, algunos trabajos no reportan diferencias significativas en el rendimiento académico, aunque sí en la percepción o el interés del estudiante (Bauer et al., 2025).

Entre las limitaciones reportadas se encuentran tamaños muestrales reducidos, contextos institucionales únicos y la necesidad de validaciones longitudinales (Bauer et al., 2025; Embarak, 2025; Li et al., 2025; Wang et al., 2022; Colliot et al., 2024; Garefalakis et al., 2025). Asimismo, se identifican desafíos relacionados con la comparabilidad metodológica, la dependencia tecnológica y los aspectos éticos del manejo de datos educativos (Sharif & Uckelmann, 2024; Sappa, 2025).

DISCUSIÓN

A nivel interpretativo, los hallazgos se alinean parcialmente con la evidencia que se reporta en la literatura reciente, pero también muestran divergencias según el tipo de tecnología, el contexto de aplicación y la asignatura (Bauer et al., 2025; Li et al., 2025; Naseer & Khawaja, 2025; Sappa, 2025; Wang et al., 2022; Wang et al., 2025). En particular, las aproximaciones basadas en LLM tienden a reportar mayor escalabilidad y rapidez (Morales-Chan et al., 2024; Sappa, 2025), mientras que los enfoques basados en Machine Learning supervisado/ensemble y los tutores inteligentes específicos de dominio muestran efectos más consistentes en tareas estructuradas y evaluables (Colliot et al., 2024; Eitemüller et al., 2023; Qadir et al., 2025; Wang et al., 2022).

La Tabla 1 integra de forma comparativa las principales tecnologías de IA, los tipos de tareas y los efectos pedagógicos reportados, permitiendo identificar relaciones causa-efecto entre el modelo tecnológico y los resultados de aprendizaje.

Tabla 1

Relación entre tecnologías de IA, tipo de tarea y efectos de la retroalimentación adaptativa

Tipo de IA	Tipo de tarea	Función principal del feedback	Efecto observado en los estudios	Relación causa-efecto
Machine Learning supervisado (RF, SVM, KNN, GRU, ANN, Stacking)	Estructurada (química, geometría, quizzes, programación básica)	Predicción temprana + feedback correctivo	Mayor rendimiento, menor carga cognitiva, menor tasa de fallo	Cuando la IA predice riesgo temprano y genera feedback específico, entonces se reduce el error y mejora el desempeño (Adnan et al., 2021; Qadir et al., 2025; Wang et al., 2022).
Tutores inteligentes y sistemas de evaluación automática	Estructurada multietapa (ecuaciones químicas, dibujos geométricos, código)	Señalización de errores y reintentos guiados	Mejora significativa en aprendizaje y transferencia cercana	Cuando el feedback indica el tipo y la ubicación del error, entonces el estudiante corrige y aprende con mayor eficacia (Colliot et al., 2024; Eitemüller et al., 2023).

LLM (GPT-3.5, GPT-4, Yuanbao, ChatGPT)	Abierta (ensayos, escritura, música, discusión)	Feedback explicativo, dialogado y metacognitivo	Mejora en autonomía, motivación y metacognición; impacto variable en rendimiento	Cuando el feedback es reflexivo y conversacional, entonces se fortalecen procesos metacognitivos más que el rendimiento directo (Bauer et al., 2025; Li et al., 2025; Naz & Robertson, 2024).
LLM en MOOCs a gran escala	Mixta (abierta + estructurada)	Feedback automático escalable basado en rúbricas	Alta satisfacción, rapidez y cobertura; costos elevados	Cuando los LLM se implementan a gran escala, entonces aumenta la cobertura del feedback, pero también el costo y los riesgos (Morales-Chan et al., 2024; Sappa, 2025).
Explainable AI (XAI)	Predicción del rendimiento en LMS	Interpretación de predicciones y razones del feedback	Mayor transparencia y confianza institucional	Cuando el sistema explica por qué predice o recomienda, entonces mejora la aceptabilidad y uso del feedback (Adnan et al., 2022; Embarak, 2025).
Multimodal (IoB, visualización, IoT, laboratorios remotos)	Práctica, programación, comportamiento	Monitoreo y ajuste del feedback en tiempo real	Mayor personalización y equidad, pero mayor complejidad	Cuando la IA integra datos multimodales, entonces la retroalimentación se ajusta mejor al comportamiento del estudiante (Embarak, 2025; Garefalakis et al., 2025; Li et al., 2025; Sharif & Uckelmann, 2024).

A partir de esta síntesis, se observa que, en tareas estructuradas de respuesta verificable, como geometría o química, los sistemas que implementan retroalimentación inmediata correctiva y específica de errores presentan mejoras más consistentes en desempeño y transferencia cercana (Colliot et al., 2024; Eitemüller et al., 2023). En contraste, en tareas abiertas, como escritura académica o entrenamiento musical, los modelos conversacionales y el andamiaje reflexivo muestran mejoras en habilidades metacognitivas, autonomía y percepción de utilidad, aunque el efecto sobre el rendimiento académico varía (Bauer et al., 2025; Li et al., 2025; Naz & Robertson, 2024; Asadi et al., 2025). En consecuencia, el tipo de tarea condiciona la efectividad del feedback y diferencia resultados cognitivos de resultados metacognitivo-afectivos (Colliot et al., 2024; Li et al., 2025).

Desde una perspectiva teórica, estos hallazgos pueden interpretarse a la luz de la teoría del aprendizaje autorregulado y del enfoque sociocultural del aprendizaje. Los sistemas que proporcionan retroalimentación inmediata y específica favorecen procesos de monitoreo y ajuste del desempeño,

elementos centrales del aprendizaje autorregulado descrito por Zimmerman. En este sentido, la retroalimentación adaptativa basada en IA no solo cumple una función correctiva, sino que actúa como un mecanismo que promueve la planificación, la reflexión y el control del propio aprendizaje (Adnan et al., 2021; Wang et al., 2022).

De forma complementaria, los sistemas conversacionales y generativos pueden interpretarse como formas de andamiaje digital dentro de la Zona de Desarrollo Próximo propuesta por Vygotsky. Estos sistemas proporcionan explicaciones, orientaciones y preguntas guiadas que apoyan al estudiante en la resolución de tareas que no podría completar de manera autónoma, funcionando como mediadores cognitivos que amplían las oportunidades de interacción formativa (Li et al., 2025; Naz & Robertson, 2024).

Respecto a las arquitecturas y estrategias, los modelos tradicionales y los enfoques de ensemble muestran ventajas en escenarios con datos tabulares o secuenciales de interacción, donde se asocian con predicción temprana y soporte a intervención docente (Qadir et al., 2025; Wang et al., 2022; Santos & Henriques, 2023). En paralelo, las propuestas de XAI aportan interpretabilidad al permitir explicaciones globales y locales desde etapas tempranas del curso, lo que fortalece la toma de decisiones docentes y facilita auditoría algorítmica (Adnan et al., 2022; Embarak, 2025). Este aporte resulta crítico porque una proporción relevante de trabajos basados en LLM no incorpora mecanismos robustos de explicabilidad, lo que dificulta justificar recomendaciones y mantener la confianza institucional (Bauer et al., 2025; Morales-Chan et al., 2024; Naz & Robertson, 2024; Sappa, 2025).

Además, la revisión identifica problemas recurrentes que afectan la comparabilidad entre estudios, como la heterogeneidad de los diseños metodológicos, la falta de estándares de evaluación comparables, la validez externa limitada por tamaños muestrales reducidos, la dependencia tecnológica de infraestructuras de alto costo y los riesgos éticos derivados del manejo de datos personales (Bauer et al., 2025; Embarak, 2025; Sharif & Uckelmann, 2024; Sappa, 2025; Wang et al., 2022).

La evidencia revisada confirma el potencial de la IA para optimizar la retroalimentación formativa y personalizar la experiencia de aprendizaje, siempre que se atiendan los desafíos de transparencia, equidad y sostenibilidad tecnológica (Adnan et al., 2022; Morales-Chan et al., 2024; Sappa, 2025; Sharif & Uckelmann, 2024). Las perspectivas futuras apuntan al desarrollo de arquitecturas híbridas que integren Explainable AI, analítica multimodal y aprendizaje por refuerzo, así como a la expansión de modelos multilingües y culturalmente contextualizados que favorezcan la inclusión educativa en América Latina y otras regiones emergentes (Embarak, 2025; Sharif & Uckelmann, 2024; Wang et al., 2025).

CONCLUSIONES

La revisión sistemática de la literatura publicada entre 2020 y 2025 evidencia que la inteligencia artificial se ha consolidado como un componente estratégico para la generación de retroalimentación adaptativa en entornos educativos virtuales. Más allá de los avances tecnológicos específicos, los hallazgos reflejan una transición desde modelos correctivos y predictivos hacia enfoques conversacionales, multimodales y centrados en el estudiante.

Desde una perspectiva teórica, los sistemas de retroalimentación adaptativa basados en IA materializan principios del aprendizaje autorregulado y del enfoque sociocultural, al facilitar procesos de monitoreo, reflexión y andamiaje cognitivo. En este sentido, la inteligencia artificial no solo actúa como herramienta tecnológica, sino como un mediador pedagógico que amplía las posibilidades de personalización y apoyo formativo.

En el plano metodológico, la literatura analizada muestra una alta heterogeneidad en los diseños experimentales, las métricas de evaluación y los contextos de aplicación, lo que limita la comparabilidad entre estudios y la generalización de los resultados. Esto evidencia la necesidad de establecer marcos de evaluación más estandarizados, estudios longitudinales y enfoques que integren dimensiones cognitivas, metacognitivas y socioemocionales del aprendizaje.

Desde una perspectiva educativa, la retroalimentación adaptativa basada en IA representa una oportunidad para ampliar la cobertura del feedback, reducir la carga docente y favorecer experiencias de aprendizaje más personalizadas y equitativas. No obstante, su implementación exige atender desafíos relacionados con la calidad de los datos, la transparencia algorítmica, la sostenibilidad tecnológica y la formación docente en el uso pedagógico de estas herramientas.

La evidencia sugiere que el futuro de la retroalimentación adaptativa se orienta hacia arquitecturas híbridas que integren modelos generativos, analítica multimodal y mecanismos de explicabilidad, con el objetivo de desarrollar sistemas más transparentes, inclusivos y pedagógicamente significativos.

Como limitación, esta revisión se restringe a estudios indexados en una única base de datos y a un periodo temporal específico, lo que podría excluir investigaciones relevantes y reducir la representatividad de algunos contextos educativos.

REFERENCIAS

- Adnan, M., AlSaeed, D. H., Al-Baity, H. H., & Rehman, A. (2021). Leveraging the power of deep learning technique for creating an intelligent, context-aware, and adaptive m-learning model. *Computational Intelligence and Neuroscience*, 2021, 5519769. <https://doi.org/10.1155/2021/5519769>
- Adnan, M., Uddin, M. I., Khan, E., Alharithi, F. S., Amin, S., & Alzahrani, A. A. (2022). Earliest possible global and local interpretation of students' performance in virtual learning environments by leveraging explainable AI. *IEEE Access*, 10, 126187–126203. <https://doi.org/10.1109/ACCESS.2022.3227072>
- Almetnawy, H., Orabi, A., Alneyadi, A. R., Ahmed, T., & Lakas, A. (2025). An adaptive intelligent tutoring system powered by generative AI. In *Proceedings of the IEEE Global Engineering Education Conference (EDUCON 2025)*. IEEE. <https://doi.org/10.1109/EDUCON62633.2025.11016362>
- Araujo, L., López-Ostenero, F., Plaza, L., & Martínez-Romo, J. (2025). Automated formative feedback for algorithm and data structure self-assessment. *Electronics*, 14(5), 1034. <https://doi.org/10.3390/electronics14051034>
- Asadi, M., Ebadi, S., Salman, A. R., Taheri, R., & Mohammadi, L. (2025). Investigating the effects of AI-assisted teacher instruction on online IELTS writing. *Social Sciences & Humanities Open*, 9, 101747. <https://doi.org/10.1016/j.ssaho.2025.101747>
- Bao, D. T. N., & Binh, D. L. (2026). Pedagogically anchored code clustering: Integrating assignment specifications with control flow and structural features. In N. T. Nguyen et al. (Eds.), *Computational intelligence in engineering science* (Communications in Computer and Information Science, Vol. 2585, pp. 352–363). Springer. https://doi.org/10.1007/978-3-031-98164-7_27
- Batita, M. S. R., Setyosari, P., Kuswandi, D., & Ulfa, S. (2024). Personalized online feedback using LMS annotation plugin: Promoting learners' self-monitoring, evaluation, and reflection. In *Proceedings of the 2024 8th International Conference on Education and Multimedia Technology (ICEMT '24)* (pp. 147–153). Association for Computing Machinery. <https://doi.org/10.1145/3678726.3678734>
- Bauer, E., Richters, C., Pickal, A. J., Klippert, M., Sailer, M., & Stadler, M. (2025). Effects of AI-generated adaptive feedback on statistical skills and interest in statistics: A field experiment in higher education. *British Journal of Educational Technology*, 56(5), 1735–1757. <https://doi.org/10.1111/bjet.13609>
- Colliot, T., Krichen, O., Girard, N., Anquetil, É., & Jamet, É. (2024). What makes tablet-based learning effective? A study of the role of real-time adaptive feedback. *British Journal of Educational Technology*, 56(5), 2278–2295. <https://doi.org/10.1111/bjet.13439>
- Eitemüller, C., Trauten, F., Striewe, M., & Walpuski, M. (2023). Digitalization of multistep chemistry exercises with automated formative feedback. *Journal of Science Education and Technology*, 32, 724–740. <https://doi.org/10.1007/s10956-023-10043-2>

- Embarak, O. (2025). A behaviour-driven framework for smart education: Leveraging explainable AI and IoB in personalized learning systems. *Procedia Computer Science*, 234, 205–214. <https://doi.org/10.1016/j.procs.2025.07.205>
- Garefalakis, M., Kamarianakis, Z., & Panagiotakis, S. (2024). Remote laboratory for developing an IoT system. In *Proceedings of the Pan-Hellenic Conference on Progress in Computing and Informatics (PCI 2024)* (pp. 315–323). ACM. <https://doi.org/10.1145/3716554.3716602>
- Gubelmann, R., Burkhard, M., Ivanova, R. V., Bermeitinger, B., & Handschuh, S. (2024). Exploring the usefulness of open and proprietary LLMs in argumentative writing support. In *Artificial intelligence in education* (Communications in Computer and Information Science, Vol. 2151, pp. 175–182). Springer. https://doi.org/10.1007/978-3-031-64312-5_21
- Li, M., Wang, D., Purwanto, E., Selig, T., Zhang, Q., & Liang, H.-N. (2025). VisualCodeMOOC: A course platform for algorithms and data structures integrating a conversational agent for enhanced learning through dynamic visualizations. *SoftwareX*, 30, 102072. <https://doi.org/10.1016/j.softx.2025.102072>
- Li, W., Cui, X., Manoharan, P., Dai, L., Liu, K., & Huang, L. (2025). AI-assisted feedback and reflection in vocal music training: Effects on metacognition and singing performance. *Frontiers in Psychology*, 16, Article 1598867. <https://doi.org/10.3389/fpsyg.2025.1598867>
- Morales-Chan, M., Amado-Salvatierra, H. R., Medina, J. A., Barchino, R., Hernández-Rizzardini, R., & Teixeira, A. M. (2024). Personalized feedback in massive open online courses: Harnessing the power of LangChain and OpenAI API. *Electronics*, 13(10), Article 1960. <https://doi.org/10.3390/electronics13101960>
- Nabil, R., Mohamed, N. E., Mahdy, A., Essam, S., & Eliwa, E. (2021). EvalSeer: An intelligent gamified system for programming assignments assessment. In *2021 International Mobile, Intelligent and Ubiquitous Computing Conference (MIUCC)* (pp. 235–242). IEEE. <https://doi.org/10.1109/MIUCC52538.2021.9447629>
- Nakanishi, T. (2023). An inquirer-responder architecture using LLMs: Emulating virtual hearing Q&A in education. In *2023 IEEE/WIC International Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT)* (pp. 526–533). IEEE. <https://doi.org/10.1109/WI-IAT59888.2023.00088>
- Naseer, F., & Khawaja, S. (2025). Mitigating conceptual learning gaps in mixed-ability classrooms: A learning analytics-based evaluation of AI-driven adaptive feedback for struggling learners. *Applied Sciences*, 15(8), Article 4473. <https://doi.org/10.3390/app15084473>
- Naz, I., & Robertson, R. (2024). Exploring the feasibility and efficacy of ChatGPT-3 for personalized feedback in teaching. *Electronic Journal of e-Learning*, 22(2), 98–111. <https://doi.org/10.34190/ejel.22.2.3345>
- Oubagine, R., Laaouina, L., Jeghal, A., & Tairi, H. (2025). Advancing MOOCs personalization: The role of generative AI in adaptive learning environments. In *Artificial intelligence in education* (Communications in Computer and Information Science, Vol. 2590, pp. 242–254). Springer. https://doi.org/10.1007/978-3-031-99261-2_22
- Qadir, H. M., Khan, R. A., Rasool, M., Sohaib, M., Shah, M. A., & Hasan, M. J. (2025). An adaptive feedback system for the improvement of learners. *Scientific Reports*, 15, Article 17242. <https://doi.org/10.1038/s41598-025-01429-w>
- Renzella, J., & Cain, A. (2020). Enriching programming student feedback with audio comments. In *Proceedings of the 2020 IEEE/ACM 42nd International Conference on Software Engineering: Software Engineering Education and Training (ICSE-SEET)* (pp. 173–183). ACM. <https://doi.org/10.1145/3377814.3381712>
- Roodsari, S. T., Köhler, T., & Azizi Ghanbari, S. (2025). Artificial intelligence-based learning objective-oriented formative feedback for students in higher education based on the instructional design. In

- Intelligent systems and applications* (Lecture Notes in Networks and Systems, Vol. 1260, pp. 504–513). Springer. https://doi.org/10.1007/978-3-031-85652-5_50
- Santos, R. M., & Henriques, R. (2023). Accurate, timely, and portable: Course-agnostic early prediction of student performance from LMS logs. *Computers and Education: Artificial Intelligence*, 5, 100175. <https://doi.org/10.1016/j.caeai.2023.100175>
- Sappa, A. (2025). Assessing the impact of large language models on the scalability and efficiency of automated feedback mechanisms in massive open online courses. *Indian Journal of Information Sources and Services*, 15(2), 275–286. <https://doi.org/10.51983/ijiss-2025.IJISS.15.2.35>
- Sharif, M., & Uckelmann, D. (2024). Multi-modal learning analytics in personalized education using deep reinforcement learning-based approach. *IEEE Access*, 12, 54049–54065. <https://doi.org/10.1109/ACCESS.2024.3388474>
- Van Campenhout, R., Dittel, J. S., & Johnson, B. G. (2026). Scaling effective characteristics of ITSs: A preliminary analysis of LLM-based personalized feedback. In *Artificial intelligence in education* (Lecture Notes in Computer Science, Vol. 15723, pp. 171–181). Springer. https://doi.org/10.1007/978-3-031-98281-1_13
- Wang, J., Zhou, Y., & Hu, J. (2025). Research on innovation and practice of empowering SPOC foreign language teaching mode with large language model. In *Proceedings of the 2025 International Conference on Education, Information Management and Service Science* (pp. 103–107). ACM. <https://doi.org/10.1145/3732299.3732319>
- Wang, X., Zhang, L., & He, T. (2022). Learning performance prediction-based personalized feedback in online learning via machine learning. *Sustainability*, 14(13), Article 7654. <https://doi.org/10.3390/su14137654>