



Doi: <https://doi.org/10.70577/asce.v5i3.996>

Recibido: 2026-06-13

Aceptado: 2026-06-23

Publicado: 2026-07-09

Feedback automatizado con inteligencia artificial y autorregulación del aprendizaje matemático en educación secundaria: una revisión sistemática de literatura 2020 a marzo 2026

Automated feedback with artificial intelligence and self-regulation of mathematical learning in secondary education: a systematic literature review 2020 to March 2026

Autor(s)

Nidia Marcela Alarcón Micolta¹

Facultad de Posgrados, Maestría en Inteligencia Artificial para la educación

nnombrealarconmicoltanidiamarcelam@unemi.edu.ec

<https://orcid.org/0009-0003-4998-6712>

Universidad Estatal de Milagro

Milagro - Ecuador

Edwin Matías Vidal Landin²

Facultad de Posgrados, Maestría en Inteligencia Artificial

evidal@unemi.edu.ec

<https://orcid.org/0009-0009-6626-7318>

Universidad Estatal de Milagro

Milagro - Ecuador

Johana Pamela Galarza Bermeo³

Facultad de Posgrados, Maestría en Inteligencia Artificial para la educación

jgalarzab7@unemi.edu.ec

<https://orcid.org/0009-0007-3928-5049>

Universidad Estatal de Milagro

Milagro - Ecuador

Como Citar

Alarcón Micolta , N. M., Vidal Landin , E. M., & Galarza Bermeo , J. P. (2026). Zeedback automatizado con inteligencia artificial y autorregulación del aprendizaje matemático en educación secundaria: una revisión sistemática de literatura 2020 a marzo 2026. *ASCE MAGAZINE*, 5(3), 418–433. <https://doi.org/10.70577/asce.v5i3.996>



Resumen

Esta revisión sistemática analiza el papel del feedback automatizado con inteligencia artificial (IA) en el desarrollo de la autorregulación del aprendizaje (ARA) matemático en educación secundaria. El estudio siguió el protocolo PRISMA 2020 y consultó siete bases de datos (Scopus, Web of Science, ERIC, SciELO, Redalyc, MDPI y Frontiers in Education) durante el período comprendido entre enero de 2020 y marzo de 2026. De 347 registros iniciales se llegó a 20 estudios para el análisis final. Los sistemas inteligentes de tutoría con modelado del conocimiento del estudiante presentan la evidencia más consistente de efectividad, seguidos por las plataformas adaptativas y los asistentes conversacionales basados en modelos de lenguaje. El monitoreo del error es la dimensión de la ARA más favorecida por el feedback automatizado; la planificación metacognitiva, en cambio, muestra resultados contradictorios que dependen del grado de autonomía que el sistema transfiere al estudiante. Las limitaciones más frecuentes son la retroalimentación superficial, la brecha digital y la tendencia a generar dependencia tecnológica cuando el diseño instruccional no contempla la progresiva transferencia de control. La revisión concluye que el feedback automatizado produce efectos sostenidos sobre la ARA únicamente cuando el docente interpreta activamente los datos del sistema y los articula con la práctica de aula.

Palabras clave: inteligencia artificial; feedback automatizado; autorregulación del aprendizaje; aprendizaje matemático; educación secundaria; revisión sistemática.



Abstract

This systematic review examines the role of AI-based automated feedback in supporting self-regulated learning (SRL) in secondary school mathematics. The study followed the PRISMA 2020 protocol and searched seven databases (Scopus, Web of Science, ERIC, SciELO, Redalyc, MDPI, and Frontiers in Education) for the period January 2020 to March 2026. From 347 initial records, 20 studies met the inclusion criteria for final analysis. Intelligent tutoring systems with student knowledge modeling show the most consistent evidence of effectiveness, followed by adaptive platforms and large language model-based conversational assistants. Error monitoring is the SRL dimension most consistently supported by automated feedback; metacognitive planning, by contrast, yields contradictory results depending on how much decision-making control the system transfers to the learner. The most recurrent limitations are superficial feedback, the digital divide, and the risk of technological dependency when instructional design does not include progressive transfer of control. The review concludes that automated feedback produces sustained effects on SRL only when teachers actively interpret system data and integrate it into classroom practice.

Keywords: artificial intelligence; automated feedback; self-regulated learning; mathematics learning; secondary education; systematic review.

Introducción

Dos de cada tres estudiantes latinoamericanos terminan la secundaria sin alcanzar el nivel mínimo de competencia matemática definido por las pruebas PISA (OCDE, 2023). El dato es conocido, pero lo que sigue siendo difuso es el mecanismo concreto que lo perpetúa. La investigación sobre aprendizaje señala uno en particular: el error matemático rara vez se corrige cuando ocurre. En un aula con 35 estudiantes, el docente no puede revisar cada procedimiento individual ni explicar a cada alumno por qué su razonamiento falló. La retroalimentación, cuando llega, lo hace tarde y se reduce a una calificación. Wisniewski et al. (2020), en un metaanálisis con 435 estudios de feedback educativo ($N > 61.000$), encontraron un efecto medio de $d = 0,48$ sobre el aprendizaje, pero advirtieron que la heterogeneidad de los resultados es tan alta que no tiene sentido hablar del feedback como intervención unitaria: lo que determina si funciona es el contenido informativo que transmite. La retroalimentación que solo confirma o niega una respuesta tiene efectos sobre la nota inmediata, no sobre la comprensión ni sobre la capacidad de autorregularse.

La inteligencia artificial lleva más de una década intentando cerrar esa brecha. Sistemas como MATHia o Carnegie Learning procesan el historial de interacciones de cada estudiante y generan retroalimentación en tiempo real, localizada en el paso del procedimiento donde ocurrió el error (Son, 2024; Gómez, 2024). Desde 2023, los asistentes conversacionales basados en modelos de lenguaje de gran escala ampliaron las posibilidades: explican en lenguaje natural, responden preguntas de seguimiento y reformulan la explicación si el estudiante no entiende a la primera (Kasneci et al., 2023). La pregunta dejó de ser si la tecnología puede dar feedback. Ahora es qué tipo de aprendizaje produce ese feedback y en quién.

La autorregulación del aprendizaje describe el conjunto de procesos por los que un estudiante establece metas, planifica su trabajo, monitorea su avance y ajusta sus estrategias según lo que va descubriendo sobre su propio desempeño (Panadero, 2023). En matemáticas, esta capacidad tiene un peso específico mayor que en otras asignaturas porque el conocimiento matemático es secuencial: quien no entiende ecuaciones lineales no puede avanzar a las cuadráticas; quien no domina las fracciones tiene dificultades permanentes con la proporcionalidad. Detectar a tiempo dónde está la propia laguna conceptual es, literalmente, la diferencia entre seguir adelante y quedarse atascado durante meses.

La relación entre el feedback automatizado y la ARA no es directa. Que un sistema entregue información inmediata sobre el error no garantiza que el estudiante la procese de manera que active una revisión estratégica. Cuando el feedback simplemente indica que la respuesta es incorrecta, el efecto observado es la repetición del mismo procedimiento o el abandono de la tarea (Mertens et al., 2022; Bellhäuser et al., 2023). Para que la retroalimentación active la fase de autorreflexión del modelo cíclico de la ARA, necesita especificar qué salió mal, por qué salió mal y ofrecer una ruta de corrección. Esa distinción entre feedback correctivo y feedback explicativo sigue siendo el predictor más consistente de si la tecnología produce autorregulación o solo produce respuestas correctas en el ejercicio siguiente.

La retroalimentación que reciben los estudiantes de secundaria en matemáticas cumple, en la práctica, una función sumativa. Se les dice si la respuesta fue correcta, se les asigna una nota y, en el mejor de los casos, se les muestra el procedimiento que debieron seguir. Esto tiene efectos sobre la calificación, pero no sobre la comprensión ni sobre la capacidad del estudiante de regularse frente a la próxima tarea. La inteligencia artificial puede corregir estructuralmente ese déficit porque genera retroalimentación a escala y en tiempo real, pero la investigación reciente deja al descubierto cuatro vacíos que la evidencia disponible no ha cerrado. El primero: qué nivel de detalle del feedback produce mejor ARA en matemáticas de secundaria. El segundo: qué componentes de la autorregulación responden mejor a la intervención tecnológica, dado que planificación, monitoreo y autoevaluación no se comportan igual ante el mismo sistema. El tercero: qué condiciones de diseño instruccional necesita la herramienta para no sustituir la reflexión del estudiante en lugar de estimularla. El cuarto: en qué medida los hallazgos obtenidos con universitarios se transfieren a una población de bachillerato, con menor autonomía académica y otra relación con la tecnología educativa (Bardach et al., 2026; Holmes et al., 2022).

El fracaso en matemáticas durante los primeros años de bachillerato rara vez se corrige solo. Quien no entiende álgebra elemental en primero acumula una deuda conceptual que se proyecta sobre todos los contenidos siguientes. Los sistemas educativos latinoamericanos enfrentan ese problema con grupos numerosos y tiempo docente insuficiente para retroalimentación individualizada. Estudiar si el feedback automatizado puede intervenir en ese punto tiene consecuencias directas para la práctica de aula en miles de instituciones de la región. El momento tecnológico actual justifica esa pregunta: los modelos de lenguaje desarrollados entre 2022 y 2025 alcanzaron niveles de competencia matemática que permiten generar

explicaciones útiles en álgebra y geometría de secundaria, y la teoría de la ARA cuenta con instrumentos validados que permiten operacionalizar sus componentes con precisión. Sin trabajos de síntesis que ordenen la evidencia acumulada, las decisiones de política educativa sobre adopción tecnológica terminan tomándose sobre supuestos en lugar de datos.

Los vacíos descritos justifican la pregunta que orienta esta revisión: ¿Cómo contribuye el feedback automatizado con inteligencia artificial al fortalecimiento de la autorregulación del aprendizaje matemático en estudiantes de educación secundaria, según la literatura científica publicada entre enero de 2020 y marzo de 2026? Para responderla, el artículo se propone: (a) identificar las principales herramientas de IA utilizadas para generar retroalimentación automatizada en el aprendizaje matemático; (b) describir los aportes del feedback automatizado al desarrollo de habilidades de ARA en estudiantes de secundaria; (c) analizar los beneficios, limitaciones y desafíos pedagógicos del uso de IA en procesos de retroalimentación educativa; y (d) sistematizar los principales hallazgos de la literatura sobre inteligencia artificial, feedback automatizado y autorregulación del aprendizaje matemático.

Materiales y métodos

El estudio adoptó el diseño de revisión sistemática de literatura siguiendo las directrices del protocolo PRISMA 2020 (Page et al., 2021; Moher et al., 2020). Este protocolo establece las fases de identificación, cribado, elegibilidad e inclusión de manera que el proceso pueda ser replicado por otro investigador con los mismos criterios.

Bases de datos y período de búsqueda

La búsqueda se ejecutó en siete bases de datos: Scopus, Web of Science (WoS), Education Resources Information Center (ERIC), Scientific Electronic Library Online (SciELO), Redalyc, MDPI y Frontiers in Education. Se eligieron estas fuentes para equilibrar bases de alto impacto internacional (Scopus, WoS) con repositorios que indexan producción latinoamericana (SciELO, Redalyc), que tiende a quedar fuera de las revisiones realizadas exclusivamente en bases anglosajonas. El período de búsqueda cubrió desde enero de 2020 hasta marzo de 2026.

Palabras clave y ecuaciones de búsqueda

Las búsquedas se ejecutaron en español e inglés con operadores booleanos. La ecuación en inglés fue la siguiente:

("automated feedback" OR "AI feedback" OR "intelligent tutoring system") AND ("self-regulated learning" OR "metacognition") AND ("mathematics" OR "math") AND ("secondary education" OR "high school")

La ecuación en español fue la siguiente:

("retroalimentación automatizada" OR "feedback con inteligencia artificial" OR "tutor inteligente") AND ("autorregulación del aprendizaje" OR "metacognición") AND ("matemáticas") AND ("educación secundaria" OR "bachillerato")

Criterios de inclusión y exclusión

La Tabla 1 presenta los criterios aplicados durante el proceso de selección.

Tabla 1

Criterios de inclusión y exclusión

Criterios de inclusión	Criterios de exclusión
Artículos con revisión de pares sobre inteligencia artificial en educación.	Documentos sin relación directa con educación o aprendizaje.
Estudios sobre feedback automatizado, sistemas inteligentes de tutoría o plataformas adaptativas.	Artículos centrados únicamente en aspectos técnicos de la IA sin aplicación educativa.
Investigaciones que aborden autorregulación, metacognición o aprendizaje autónomo.	Estudios sin variables relacionadas con autorregulación o metacognición.
Estudios aplicados al aprendizaje matemático o disciplinas cuantitativas afines.	Investigaciones sin relación con matemáticas ni con educación secundaria.
Publicaciones entre enero de 2020 y marzo de 2026.	Documentos fuera del período, duplicados o sin acceso al texto completo.
Artículos en español o inglés.	Opiniones, editoriales, blogs o documentos sin revisión científica.

Nota. Elaborado por el autor.

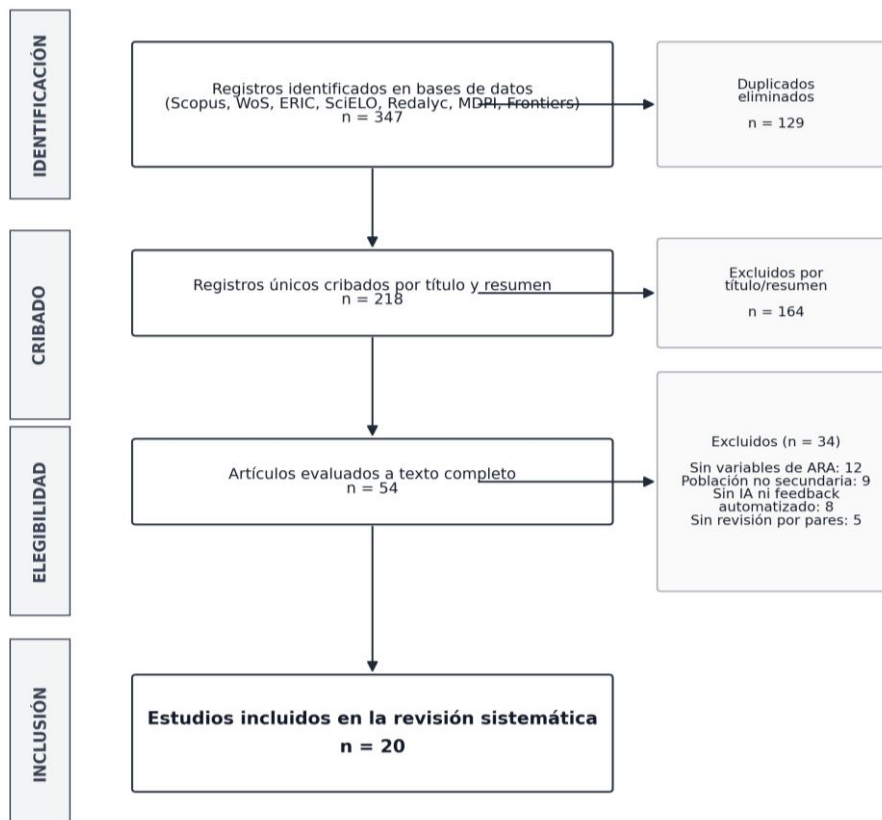
Proceso de selección

La búsqueda inicial arrojó 347 registros. Tras eliminar 129 duplicados, se obtuvieron 218 documentos únicos. La revisión de títulos y resúmenes excluyó 164 artículos que no se

ajustaban al objeto de estudio, dejando 54 textos para evaluación a texto completo. La lectura íntegra de estos artículos, contrastando cada uno con los criterios definidos, derivó en la exclusión de 34 trabajos por las siguientes razones: ausencia de variables de ARA ($n = 12$), población no perteneciente a educación secundaria ($n = 9$), ausencia de feedback automatizado o de inteligencia artificial ($n = 8$) y publicación sin revisión por pares ($n = 5$). El corpus final quedó conformado por 20 estudios. El flujo completo del proceso se representa en la Figura 1.

Figura 1

Diagrama de flujo PRISMA para selección de investigaciones



Estrategia de análisis

El análisis se estructuró mediante una matriz de sistematización que registró, para cada uno de los 20 estudios incluidos: año y país del estudio, diseño metodológico, características de la muestra, herramienta de IA utilizada, dimensiones de la ARA medidas, instrumento de medición y resultados principales. A partir de esa matriz se identificaron tres ejes temáticos que organizan la sección de resultados.

Resultados

Herramientas de inteligencia artificial utilizadas para feedback automatizado

De los 20 estudios analizados, 11 utilizaron sistemas inteligentes de tutoría (ITS) como herramienta principal. MATHia y Carnegie Learning son los más citados, especialmente en investigaciones sobre álgebra de secundaria realizadas en Estados Unidos. Lo que distingue a estos sistemas de otras plataformas digitales es su arquitectura de modelado del conocimiento: no solo registran si la respuesta fue correcta, sino que infieren qué subhabilidad conceptual está fallando y ajustan la secuencia de ejercicios en consecuencia (Son, 2024). Esta capacidad diagnóstica permite que el feedback localice el error en el paso del procedimiento donde ocurrió, no en el resultado final. Bardach et al. (2026), en un estudio longitudinal con estudiantes de secundaria que usaron un ITS de matemáticas durante un semestre, encontraron que el efecto sobre el rendimiento fue positivo pero dependía fuertemente de que el docente revisara regularmente los reportes del sistema y los usara para ajustar la instrucción grupal.

Las plataformas adaptativas aparecen en ocho estudios. Khan Academy es la más frecuente, en parte por su acceso gratuito y su disponibilidad en español. A diferencia de los ITS clásicos, estas plataformas usan algoritmos de recomendación para seleccionar el ejercicio siguiente según el historial reciente, sin modelar el conocimiento subyacente del estudiante. El feedback que producen es más limitado: señala el error, ofrece una pista o un video de revisión y propone práctica adicional. Huang et al. (2024) compararon en un estudio cuasiexperimental dos tipos de feedback basado en datos en clases de matemáticas: el feedback orientado a la autorregulación del aprendizaje produjo mejoras significativas en los procesos de monitoreo y revisión de estrategias, mientras que el feedback orientado exclusivamente a la tarea mejoró el desempeño inmediato, pero no la ARA.

Los asistentes conversacionales basados en modelos de lenguaje de gran escala aparecen en seis estudios, todos publicados entre 2023 y 2026. ChatGPT, GPT-4 y Gemini integrados en entornos educativos son los más mencionados. Su ventaja frente a los ITS clásicos es la flexibilidad expresiva: pueden explicar en lenguaje natural, responder preguntas adicionales del estudiante y reformular una explicación si no fue comprendida. Kasneci et al. (2023) documentaron tasas de error conceptual de entre 8% y 17% en problemas algebraicos de secundaria, lo que limita su uso autónomo sin supervisión docente. Mejez et al. (2024), en un estudio de métodos mixtos, encontraron que el feedback adaptativo generado digitalmente

mejoró algunos componentes de la ARA, aunque los efectos eran heterogéneos según el nivel previo de los estudiantes.

Cinco estudios emplearon sistemas de evaluación automática de respuestas abiertas basados en procesamiento de lenguaje natural. Estos sistemas evalúan no solo si la respuesta numérica es correcta, sino la coherencia del razonamiento expresado en lenguaje escrito. En tareas de justificación matemática, donde el estudiante debe explicar por qué su procedimiento es válido, esta modalidad de retroalimentación representa un avance respecto a los sistemas de respuesta cerrada. Afzaal et al. (2021) demostraron que el feedback explicable basado en IA, combinado con recomendaciones de acción concretas, favoreció la autorregulación de los estudiantes con más consistencia que el feedback puramente informativo.

Aportes del feedback automatizado a la autorregulación del aprendizaje

El patrón que emerge de los 20 estudios es claro en su asimetría: el monitoreo del error es la dimensión de la ARA que responde con más consistencia al feedback automatizado, mientras que la planificación metacognitiva produce resultados contradictorios.

Catorce estudios documentan mejoras en la capacidad del estudiante para identificar y categorizar sus propios errores. La función básica de cualquier sistema de feedback, incluso el más rudimentario, es hacer visible la discrepancia entre el desempeño actual y el esperado. Lo que añade la evidencia reciente es que cuando el sistema devuelve no solo el error puntual sino el patrón acumulado (qué tipo de errores se repiten, en qué contextos aparecen), los estudiantes construyen representaciones más precisas de sus dificultades. Bellhäuser et al. (2023), en un experimento de campo longitudinal con asignación aleatoria, encontraron que el feedback automatizado diario mejoró la autorregulación del aprendizaje de manera significativa respecto al grupo control, con efectos más pronunciados en los estudiantes que recibían información sobre sus patrones de error a lo largo del tiempo.

La autoevaluación, entendida como la capacidad de juzgar la calidad del propio trabajo antes de recibir retroalimentación externa, aparece fortalecida en diez estudios. El mecanismo es indirecto: cuando el estudiante observa, a lo largo de semanas, una correlación entre sus propios juicios y los diagnósticos del sistema calibra mejor sus expectativas sobre su desempeño. Panadero (2023) señala que este efecto de calibración es uno de los aportes más documentados de los sistemas de evaluación continuada, pero también advierte que depende de la calidad del

mensaje de feedback recibido: la retroalimentación que solo indica correcto o incorrecto no produce calibración metacognitiva.

El ajuste de estrategias aparece en ocho estudios, pero únicamente en aquellos donde el feedback ofrece una explicación del principio matemático que el procedimiento violó y propone un enfoque alternativo. Mertens et al. (2022), en un metaanálisis sobre feedback computarizado y resultados de aprendizaje, encontraron que el feedback con elaboración produce efectos significativamente mayores sobre habilidades de orden superior que el feedback correctivo simple, resultado que se mantiene en distintos diseños y poblaciones.

La planificación es el componente más difícil de afectar con feedback automatizado. Solo cuatro estudios la abordan directamente, con resultados que se contradicen. Algunos reportan que el uso sostenido de plataformas adaptativas mejora la capacidad del estudiante de establecer metas; otros sugieren que cuando el algoritmo decide automáticamente qué tarea viene a continuación, el estudiante no necesita planificar porque el sistema lo hace por él. Mejuh et al. (2024) identificaron esta tensión y la denominan el dilema de la adaptación: cuanto más eficiente es el sistema en seleccionar la tarea óptima, menos espacio deja para que el estudiante ejercite su propia agencia metacognitiva.

Beneficios y limitaciones del uso de IA en el aprendizaje matemático

La inmediatez del feedback aparece en 16 de los 20 estudios como el beneficio más documentado. Recibir retroalimentación en segundos en lugar de días impide que el estudiante consolide procedimientos incorrectos y mantiene el flujo de la tarea. Son (2024), en su revisión sistemática sobre ITS en matemáticas, reporta tamaños de efecto sobre el rendimiento en álgebra que oscilan entre $d = 0,35$ y $d = 0,52$ en estudios de uso sostenido durante ocho semanas o más.

La personalización de la secuencia de aprendizaje es el segundo beneficio más citado. Los ITS y las plataformas adaptativas generan rutas diferenciadas para cada estudiante según su historial de errores, algo que un docente con 35 alumnos no puede hacer manualmente. Gómez (2024), en una revisión de tendencias sobre ITS en matemáticas, concluye que los sistemas con mayor grado de adaptación producen resultados más consistentes que los sistemas de navegación libre, especialmente en contenidos procedimentales.

Las limitaciones son igualmente relevantes. La retroalimentación superficial es la más recurrente: cuando el sistema solo indica si la respuesta es correcta o presenta la solución sin explicar el error, los efectos sobre la ARA no se observan, aunque sí se registren ganancias en el rendimiento inmediato (Mertens et al., 2022). Esto no es un problema técnico sino de diseño pedagógico: muchas de las plataformas más accesibles económicamente son precisamente las que ofrecen feedback más superficial.

La brecha digital aparece en ocho estudios como limitación estructural. Dos de ellos, realizados en México y Colombia, reportan que entre el 30% y el 35% de los estudiantes de secundaria en zonas rurales carece de conectividad suficiente para el uso continuado de plataformas educativas. Esa restricción rompe la lógica adaptativa de los sistemas, que requieren acumulación sostenida de datos para ajustar su funcionamiento.

El riesgo de dependencia tecnológica aparece en seis estudios. Cuando el estudiante recurre al sistema antes de intentar resolver el problema por sí mismo, el feedback automatizado deja de ser retroalimentación y se convierte en sustituto del trabajo cognitivo. Meje et al. (2024) señalan que este efecto no es inherente a la tecnología sino al diseño: cuando la ayuda se ofrece antes de que el estudiante la solicite, la dependencia aumenta; cuando requiere una acción explícita para activarse, el efecto desaparece.

La ausencia de integración docente activa aparece en cinco estudios como factor moderador negativo. Los ITS generan reportes detallados sobre el desempeño individual y grupal, pero esos reportes son inútiles si el docente no los lee o no sabe qué hacer con ellos. Bardach et al. (2026) documentaron que los estudiantes cuyos docentes revisaban regularmente los informes del sistema mostraban mejoras en ARA significativamente mayores que aquellos cuyos docentes usaban el sistema como actividad complementaria sin integración instruccional.

Discusión

Los hallazgos de esta revisión permiten una respuesta que no es ni optimista ni pesimista sobre la tecnología: el feedback automatizado con IA contribuye a la ARA matemática en secundaria, pero esa contribución depende de variables que no están en el sistema, sino en cómo se diseña su uso pedagógico.

El punto de convergencia más sólido entre los estudios es el efecto sobre el monitoreo del error. No sorprende: la función básica de cualquier sistema de feedback es hacer visible la

discrepancia entre el desempeño actual y el esperado. Lo que añade la literatura reciente es que ese efecto se extiende a otras dimensiones de la ARA solo cuando el feedback comunica el principio matemático subyacente al error, no únicamente si la respuesta fue correcta. Mertens et al. (2022) sistematizan esta distinción en su metaanálisis: el feedback con elaboración produce efectos sustancialmente mayores sobre habilidades de orden superior. Esto tiene una implicación práctica directa: el tipo de feedback que más se usa en las plataformas escolares (el más barato de implementar, el que solo valida o rechaza respuestas) es también el menos efectivo para la ARA.

La principal contradicción se localiza en la planificación metacognitiva. Algunos estudios reportan mejoras después del uso sostenido de plataformas adaptativas; otros no encuentran efecto o reportan deterioro. Mejez et al. (2024) identifican la variable explicativa: cuando la plataforma controla la secuencia de contenidos, la planificación del estudiante se inhibe porque no hay nada que planificar. La implicación no es que los sistemas adaptativos sean malos, sino que su uso debe diseñarse para que el estudiante conserve agencia sobre al menos algunos aspectos de su trayectoria.

Sobre cuál herramienta es más efectiva, la evidencia favorece a los ITS con modelado del conocimiento. Pero esa superioridad viene con un costo: licencias costosas, infraestructura tecnológica y la necesidad de un docente que interprete y use activamente los datos que el sistema produce (Bardach et al., 2026). Las plataformas adaptativas son más accesibles y más extendidas, pero sus efectos sobre la ARA son más débiles. Los asistentes basados en modelos de lenguaje son los más flexibles, pero su fiabilidad matemática es todavía insuficiente para uso autónomo sin verificación docente (Kasneci et al., 2023). Ninguna herramienta domina en todos los criterios relevantes.

El rol del docente emerge como variable moderadora consistente. El título del artículo de Bardach et al. (2026) resume el hallazgo con precisión: *Intelligent Tutoring Systems Need Teachers*. La IA no reemplaza la mediación pedagógica; la reorganiza. Cuando el docente interpreta los reportes del sistema y los conecta con decisiones de aula, los efectos sobre la ARA son significativamente mayores. Cuando el sistema opera como actividad paralela sin integración instruccional, los efectos se diluyen. Esta conclusión tiene implicaciones directas para la formación docente: el acceso a la tecnología es necesario, pero no suficiente; lo que hace la diferencia es la competencia del docente para darle un uso pedagógico (Holmes et al., 2022).

Una advertencia metodológica cierra la discusión. La mayor parte de los estudios incluidos provienen de contextos con conectividad estable e infraestructura tecnológica adecuada. Los efectos documentados probablemente sobreestiman lo que se observaría en implementaciones masivas en contextos latinoamericanos con brecha digital significativa. Extrapolar sin esa cautela sería metodológicamente irresponsable.

Conclusiones

La revisión derivó cinco conclusiones específicas, articuladas con los objetivos del estudio.

Los sistemas inteligentes de tutoría con modelado del conocimiento del estudiante tienen la evidencia más consistente de efectividad sobre el rendimiento matemático y la ARA. Su capacidad diagnóstica localiza el error donde ocurre, condición necesaria para que el feedback active procesos de revisión metacognitiva. Las plataformas adaptativas son más accesibles, pero producen efectos más débiles sobre la ARA cuando su diseño no incluye mecanismos de transferencia progresiva de autonomía al estudiante.

El monitoreo del error es el componente de la ARA más favorecido por el feedback automatizado. La planificación metacognitiva presenta resultados contradictorios que dependen de si el sistema controla o deja al estudiante la secuencia de aprendizaje. Esto sugiere que el diseño instruccional, no la sofisticación técnica del sistema determina qué dimensiones de la ARA se desarrollan y cuáles quedan inhibidas.

El feedback automatizado produce efectos sostenidos sobre la ARA únicamente cuando el docente integra activamente los datos del sistema en su práctica de aula. La tecnología no sustituye la mediación pedagógica: la reorganiza. Las intervenciones con efectos más consistentes son aquellas donde el docente usa los reportes del sistema para ajustar su instrucción grupal y orientar la reflexión metacognitiva individual.

La brecha digital no es una limitación periférica: afecta de forma estructural los beneficios que pueden obtenerse. Los estudiantes de zonas rurales o con conectividad irregular no acumulan el historial de interacciones que los sistemas adaptativos necesitan para funcionar. Cualquier política de adopción tecnológica que no contemple esta restricción amplía la desigualdad en lugar de reducirla.



El riesgo de dependencia tecnológica no es inherente al feedback automatizado; depende del diseño. Cuando el sistema entrega la ayuda antes de que el estudiante la solicite o decide todas las rutas de aprendizaje, la autonomía metacognitiva se deteriora. Cuando el feedback está disponible pero requiere una acción del estudiante para activarse, la dependencia desaparece. Esta diferencia de diseño, aparentemente técnica, determina si la tecnología desarrolla la ARA o la reemplaza.

Referencias Bibliográficas

- Afzaal, M., Nouri, J., Zia, A., Papapetrou, P., Fors, U., Wu, Y., Li, X., & Weegar, R. (2021). Explainable AI for data-driven feedback and intelligent action recommendations to support students' self-regulation. *Frontiers in Artificial Intelligence*, 4, 723447. <https://doi.org/10.3389/frai.2021.723447>
- Bardach, L., Moeller, K., Ruiz-Garcia, M., Strittmatter, Y., Meyer, J., Musslick, S., & Spitzer, M. (2026). Intelligent tutoring systems need teachers. *Journal of Computer Assisted Learning*, 42(1), e70159. <https://doi.org/10.1002/jcal.70159>
- Bellhäuser, H., Dignath, C., & Theobald, M. (2023). Daily automated feedback enhances self-regulated learning: A longitudinal randomized field experiment. *Frontiers in Psychology*, 14, 1125873. <https://doi.org/10.3389/fpsyg.2023.1125873>
- Gómez, S. (2024). Systematic review: Trends in intelligent tutoring systems in mathematics teaching and learning. *International Journal of Education in Mathematics, Science, and Technology*, 12(1), 203–229. <https://doi.org/10.46328/ijemst.3189>
- Holmes, W., Porayska-Pomsta, K., Holstein, K., Sutherland, E., Baker, T., Shum, S. B., Santos, O. C., Rodrigo, M. T., Cukurova, M., Bittencourt, I. I., & Koedinger, K. R. (2022). Ethics of AI in education: Towards a community-wide agenda. *Journal of Learning Analytics*, 9(1), 1–23. <https://doi.org/10.18608/jla.2022.7527>
- Huang, J., Cai, Y., Lv, Z., Huang, Y., & Zheng, X.-L. (2024). Toward self-regulated learning: Effects of different types of data-driven feedback on pupils' mathematics word problem-solving performance. *Frontiers in Psychology*, 15, 1356852. <https://doi.org/10.3389/fpsyg.2024.1356852>
- Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, 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>



- Mejeh, M., Sarbach, L., & Hascher, T. (2024). Effects of adaptive feedback through a digital tool: A mixed-methods study on the course of self-regulated learning. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-024-12510-8>
- Mertens, U., Finn, B., & Lindner, M. A. (2022). Effects of computer-based feedback on lower- and higher-order learning outcomes: A network meta-analysis. *Journal of Educational Psychology*, 114(8), 1743–1772. <https://doi.org/10.1037/edu0000764>
- Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2020). Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. *PLOS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
- OCDE. (2023). PISA 2022 results (Volume I): The state of learning and equity in education. OECD Publishing. <https://doi.org/10.1787/53f23881-en>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Panadero, E. (2023). Toward a paradigm shift in feedback research: Five further steps influenced by self-regulated learning theory. *Educational Psychologist*, 58(3), 193–204. <https://doi.org/10.1080/00461520.2023.2210808>
- Son, T. (2024). Intelligent tutoring systems in mathematics education: A systematic literature review using the substitution, augmentation, modification, redefinition model. *Computers*, 13(10), 270. <https://doi.org/10.3390/computers13100270>
- Wisniewski, B., Zierer, K., & Hattie, J. (2020). The power of feedback revisited: A meta-analysis of educational feedback research. *Frontiers in Psychology*, 10, 3087. <https://doi.org/10.3389/fpsyg.2019.03087>

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.