

Inteligencia Artificial Pedagógica y Analítica Cognitiva: Modelos Adaptativos para Optimizar la Autorregulación y la Transferencia del Conocimiento en Educación Básica STEM

*Pedagogical Artificial Intelligence and Cognitive Analytics: Adaptive
Models to Optimize Self-Regulation and Knowledge Transfer in
STEM Basic Education*

Daniela Silvana Benavides Espín^{1*} <https://orcid.org/0009-0004-3766-1336>

¹Ministerio de Educación Deporte y Cultura del Ecuador Pichincha- Ecuador

*Autor para la correspondencia: daniela.benavides@educacion.gob.ec

Recibido: 02/06/2025

Aceptado: 29/07/2025

Resumen

Esta investigación se centra en la mejora de las prácticas de autorregulación del aprendizaje sobre la retención y transferencia de conocimientos y el logro cognitivo dentro de las disciplinas de STEM en la educación primaria, utilizando un modelo adaptativo que incorpora IA pedagógica y analíticas computacionales. Se implementó una metodología de métodos mixtos a través de un diseño quasi-experimental complementado por análisis cualitativos de interacciones y patrones cognitivos. La integración de la intervención fue diseñada para asistir a los estudiantes en el desarrollo del aprendizaje autodirigido; la capacidad para resolver problemas complejos se integró utilizando sistemas de seguimiento en tiempo real, retroalimentación adaptativa y la exhibición de indicadores metacognitivos. La muestra consistió en estudiantes de primaria y secundaria, organizados en grupos experimentales y de control. Los resultados muestran mejoras significativas en la planificación, monitoreo, evaluación y transferencia conceptual en el grupo experimental, lo que demuestra la efectividad del modelo adaptativo en el fortalecimiento de las

habilidades STEM. Además, los análisis cualitativos revelaron una mayor conciencia metacognitiva, un uso estratégico de los recursos digitales y una participación más activa en tareas de razonamiento complejo. La integración de caminos de aprendizaje diferenciados de IA-P y la posibilidad de intervenciones oportunas, mientras que la analítica cognitiva ayudó a aclarar procesos internos que anteriormente habían sido opacos en el aula tradicional. Los hallazgos enfatizan el uso de tecnologías inteligentes para impulsar un cambio sistémico en la educación al fomentar experiencias de aprendizaje individualizadas e inclusivas habilitadas por la tecnología centradas en habilidades esenciales del siglo XXI. Se concluye que la combinación de IA-ED y analítica cognitiva es una estrategia prometedora para la mejora del aprendizaje profundo y la resolución de problemas en el contexto de la educación contemporánea.

Palabras clave: Inteligencia Artificial Educativa, Analítica del Aprendizaje, Modelos Adaptativos, Autorregulación del Aprendizaje, Transferencia del Conocimiento, Educación STEM.

Abstract

This study focuses on improving self-regulated learning practices related to knowledge retention, knowledge transfer, and cognitive achievement within STEM disciplines in primary education, using an adaptive model that integrates pedagogical AI and computational analytics. A mixed-methods methodology was implemented through a quasi-experimental design complemented by qualitative analyses of interactions and cognitive patterns. The intervention was designed to support students in developing self-directed learning; the capacity for solving complex problems was incorporated through real-time monitoring systems, adaptive feedback, and the display of metacognitive indicators. The sample consisted of primary and lower-secondary students, organized into experimental and control groups. The results show significant improvements in planning, monitoring, evaluation, and conceptual transfer in the experimental group, demonstrating the effectiveness of the adaptive model in strengthening STEM-related skills. In addition, qualitative analyses revealed heightened

metacognitive awareness, strategic use of digital resources, and more active engagement in complex reasoning tasks. The integration of differentiated learning pathways through pedagogical AI enabled timely interventions, while cognitive analytics helped clarify internal processes that had previously remained opaque in traditional classroom settings. The findings highlight the use of intelligent technologies to drive systemic change in education by fostering individualized and inclusive technology-enabled learning experiences centered on essential 21st-century skills. It is concluded that the combination of AI-based educational systems and cognitive analytics represents a promising strategy for enhancing deep learning and problem solving within the context of contemporary education.

Keywords: *Educational Artificial Intelligence, Learning Analytics, Adaptive Learning Models, Self-Regulated Learning, Knowledge Transfer, STEM Education.*

1. Introducción

La integración de la Inteligencia Artificial Pedagógica (P-AI) y la Analítica Cognitiva es un eje emergente de innovación pedagógica en contextos STEM de educación secundaria baja (Cabero-Almenara, J., et al, 2023). El desarrollo de tecnologías inteligentes permite el monitoreo de patrones cognitivos, proporcionando retroalimentación adaptativa y previniendo dificultades en tiempo real, estableciendo así un entorno que está adaptado y es propicio para el autocuidado. Por lo tanto, es crucial que los estudiantes comprendan la alfabetización digital, que a su vez les permite aprovechar estas herramientas y fomentar la adopción de estrategias de aprendizaje autodirigido y profundo (Moreira-Fontán et al., 2023).

En este contexto, los modelos adaptativos potenciados por IA abren nuevas vías para revolucionar la forma en que se enseña y aprende, no solo en términos de adaptación de contenidos, sino también en el refuerzo de los procesos metacognitivos asociados a la autorregulación y la transferencia del

aprendizaje. La evidencia reciente sugiere que los sistemas basados en analítica de aprendizaje identifican caminos cognitivos, detectan luchas tempranas y diseñan apoyos oportunos que mejoran la autonomía del aprendiz (Sánchez-Caballé et al., 2021; Romero-Zaldivar et al., 2011).

Pero esto deja un vacío en la investigación en educación básica STEM, donde la maduración cognitiva y metacognitiva tiene rasgos particulares. Esta investigación busca abordar esta laguna, a través de un modelo adaptativo de Analítica Cognitiva y P-AI, con énfasis en la autorregulación y la transferencia conceptual en estudiantes de educación básica.

Investigaciones recientes sobre la personalización del aprendizaje STEM a través de IA sugieren efectos positivos en el rendimiento, caminos cognitivos adaptativos y retroalimentación inteligente, como revela la revisión de (Zhai et al 2022) la revisión de revela que muestra mejoras sostenidas en entornos enriquecidos con tecnología adaptativa. El concepto cuenta con el respaldo de trabajos como los programas de autorregulación dirigidos, que han indicado el uso de herramientas de aprendizaje basadas en analítica para determinar estrategias, problemas y patrones de desregulación (Ifenthaler & Yau, 2020; Viberg et al., 2020).

Investigaciones desde América Latina indican que la incorporación de tecnologías digitales en las aulas estimula la autonomía de los alumnos y mejora su capacidad reflexiva, particularmente cuando están conectadas con metodologías activas, así como con retroalimentación constante (Moreira-Fontán et al., 2023). Además, (Cabero-Almenara, J., et al, 2023) señalan que la IA generativa y los sistemas inteligentes aumentan el aprendizaje guiado, siempre que se construyan dentro de criterios educativos sólidos.

Mientras tanto, los estudios en STEM escolar demuestran que la autorregulación es un mediador crítico de cómo los estudiantes movilizan su conocimiento con respecto a nuevas situaciones, especialmente en entornos digitales (Lai y Hwang, 2019). De manera similar, Romero-Zaldivar et al. (2021)

descubrieron que la analítica interaccional permite rastrear las decisiones cognitivas clave para la comprensión de la transferencia de conocimiento.

La integración de la Inteligencia Artificial Pedagógica (IA-P) y la analítica cognitiva es un eje emergente para la innovación educativa en contextos STEM de la educación básica. El desarrollo de tecnologías inteligentes permite el monitoreo de patrones cognitivos, generando retroalimentación adaptativa y anticipando dificultades en tiempo real, favoreciendo entornos de aprendizaje personalizados y constructivos (Cabero-Almenara, J., et al, 2023). Además, la alfabetización digital emerge como un componente decisivo para que los estudiantes utilicen tales herramientas y movilicen estrategias para el aprendizaje autodirigido y profundo (Moreira-Fontán et al., 2023).

En este panorama, los modelos adaptativos impulsados por IA ofrecen nuevas posibilidades para transformar las dinámicas de enseñanza-aprendizaje, no solo a través de la personalización de contenidos, sino en el fortalecimiento de procesos metacognitivos vinculados a la autorregulación y la transferencia de conocimiento. La evidencia reciente sugiere que los sistemas basados en analítica de aprendizaje pueden ser utilizados para identificar caminos cognitivos, detectar dificultades tempranas y diseñar apoyos oportunos que promuevan la autonomía de los estudiantes (Sánchez-Caballé et al., 2021; Romero-Zaldivar et al., 2021).

Sin embargo, la mayoría de estos avances se han estudiado en la educación superior, dejando un vacío significativo en su uso en STEM en K-12, que se caracteriza por una maduración cognitiva y metacognitiva particular. El enfoque de este estudio es llenar este vacío desarrollando un modelo adaptativo de IA-P y analítica cognitiva centrado en la autorregulación y la transferencia conceptual en estudiantes de K-12.

Las investigaciones recientes sobre el aprendizaje personalizado en STEM utilizando IA reflejan efectos positivos en el rendimiento, la adaptación de caminos cognitivos y la retroalimentación inteligente, como se observa en la

revisión de Zhai et al. (2022), que muestra mejoras sostenidas en entornos enriquecidos con tecnología adaptativa. El concepto cuenta con el respaldo de trabajos como los programas de autorregulación dirigidos, que han indicado el uso de herramientas de aprendizaje basadas en analítica para determinar estrategias, problemas y patrones de desregulación (Ifenthaler & Yau, 2020; Viberg et al., 2020).

En el sector educativo, las investigaciones latinoamericanas muestran que estas actividades educativas vigorizan la autonomía del aprendiz y mejoran la autorreflexión, particularmente cuando están vinculadas a metodologías activas y retroalimentación continua (Moreira-Fontán et al., 2023). La investigación también advierte que la IA generativa y los sistemas inteligentes pueden apoyar un aprendizaje enriquecido, siempre que se mantenga el estrecho vínculo con las políticas educativas establecidas (Cabero-Almenara & Palacios-Rodríguez, 2021).

Por otro lado, los estudios sobre STEM escolar revelan que la originalidad propia es un mediador vital en la medida en que los estudiantes pueden transferir su conocimiento a nuevas situaciones y la maestría del contenido en entornos digitales (Lai y Hwang 2019). De hecho, también se ha observado que la analítica de interacción puede ayudar a mapear y comprender algunas de las decisiones cognitivas significativas tomadas dentro de escenarios de aprendizaje que pueden contribuir a la transferencia de conocimiento en estos sistemas (Romero-Zaldivar et al., 2021).

Estos hallazgos destacan un consenso: la IA-P así como la analítica cognitiva tiene el potencial de mejorar la originalidad propia y el aprendizaje personalizado dentro de STEM. Sin embargo, al abordar estos sistemas de aprendizaje en la educación primaria, la investigación sobre este asunto ha sido limitada (Holmes, W., Bialik, M., & Fadel, C. (2023).

En los últimos años, la educación en América Latina ha crecido en el uso de recursos tecnológicos, metodologías activas y modelos adaptativos para

fortalecer los procesos cognitivos y metacognitivos en la educación básica y secundaria. Y, de hecho, numerosos estudios muestran la necesidad de avanzar hacia enfoques personalizados que puedan servir a la diversidad cognitiva de los aprendices y fomentar un aprendizaje profundo en STEM. En este sentido, la investigación sobre recursos manipulativos, resolución de problemas y estrategias específicas para el desarrollo del pensamiento lógico ha revelado mejoras significativas en la comprensión de conceptos abstractos y razonamiento matemático (Alarcón Burneo et al., 2024; Álvarez Piza et al., 2024a, 2024b; Fierro Barrera et al., 2024). Debido a esto, aunque es significativo, esto sirve como puntos de partida actuales que, solo para intervenciones tradicionales, no logran hacer un uso más rico de la analítica cognitiva y la inteligencia artificial en la observación del proceso de aprendizaje.

Además, los problemas analizados en relación con metodologías activas en curso, por ejemplo, aula invertida, aprendizaje basado en proyectos, aprendizaje basado en problemas y juego de roles han mostrado impactos positivos en autonomía de aprendizaje, rendimiento y creatividad, afirmando que los estudiantes responden favorablemente en situaciones de aprendizaje que los sitúan en el centro del proceso de aprendizaje (Montenegro Muñoz et al., 2024; Jiménez Bajaña et al., 2024; Bernal Párraga et al., 2024a; Bernal Parraga et al., 2024c). No obstante, estas metodologías tienen limitaciones cuando se requiere la determinación en tiempo real de estrategias de autorregulación y patrones cognitivos empleados por los estudiantes, lo que sugiere que deben complementarse con sistemas basados en IA que puedan generar retroalimentación adaptativa.

El campo de la inteligencia artificial en la educación ha realizado avances notables, incluidos estudios sobre la personalización del aprendizaje a través de plataformas adaptativas, aplicaciones de IA y chatbots educativos, particularmente en Matemáticas, Ciencias Naturales y Lenguas Extranjeras (Santana Mero et al., 2024; Zamora Arana et al., 2024; Guishca Ayala et al., 2024; Jara Chiriboga et al., 2025). Este material informa que la IA mejora la motivación, la precisión de los comentarios y la configuración de tareas

individualizadas, pero aún no amplía el análisis cognitivo como herramienta para modelar los procesos internos de los estudiantes o mejorar el aprendizaje autorregulado.

Además, los estudios sobre evaluación digital, plataformas adaptativas y gamificación han dado lugar a avances significativos para mejorar el compromiso escolar, mejorar el rendimiento y optimizar la retroalimentación (Quiroz Moreira et al., 2024; Bernal Parraga et al., 2024d; García Carrillo et al., 2024; Bernal Parraga et al., 2025). Estos hallazgos han indicado una tendencia creciente hacia la digitalización pedagógica, pero han revelado una laguna en el análisis de datos cognitivos y en la comprensión profunda de cómo los estudiantes se autorregulan en el aprendizaje dentro de entornos inteligentes.

Además, múltiples estudios en educación infantil y primaria han enfatizado la necesidad de desarrollar competencias STEM, habilidades sociales y estrategias inclusivas a través de trabajos de proyectos colaborativos y enfoques innovadores (Bernal Parraga et al., 2024e; Bernal Párraga et al., 2024f; Arequipa Molina et al., 2024; Bernal Párraga et al., 2024g; Cosquillo Chida et al., 2025). A pesar de que estos trabajos confirman la importancia de la innovación educativa, estos temas contemporáneos no incorporan modelos innovadores impulsados por IA para monitorear, predecir y adaptar el proceso de aprendizaje según el perfil cognitivo del estudiante (Bernal Parraga et al., 2024b, p. 4).

Por último, los estudios de integración STEM y metodologías activas marcaron un avance significativo, pero nuevamente, necesitan sistemas que entrelacen el aprendizaje desde una perspectiva más cognitiva, predictiva y personalizada (Bernal Párraga et al., 2024h; Bernal Párraga et al., 2024i). En lo diverso, esta literatura del revisor significativo demuestra que persiste una brecha significativa entre la Articulación de la Inteligencia Artificial Pedagógica y la Analítica Cognitiva en la optimización de la autorregulación y la transferencia de conocimiento en la Educación Básica STEM, fundamentando la necesidad de este examen.

A pesar de los logros alcanzados en la aplicación de la IA a la educación y en la analítica de aprendizaje en este campo, todavía hay “brechas” en su uso en educación primaria, especialmente en los campos de conocimiento STEM, en los que la autorregulación y la transferencia son importantes para el éxito académico. La incorporación efectiva de estos modelos y, en general, el empleo de los datos cognitivos de los estudiantes para dar la retroalimentación pedagógica verdaderamente útil necesita más evidencia empírica.

Como consecuencia, surge la pregunta central de investigación, de la siguiente manera: ¿Cómo podrían los Modelos de Sistemas Adaptativos, que combinan IA y Analítica Cognitiva, optimizar la autorregulación del aprendizaje y mejorar la transferencia de conocimiento de los estudiantes de Educación Básica en el campo STEM?

La justificación del estudio se deriva de la convergencia teórica y empírica de tres componentes clave, a saber, la autorregulación del aprendizaje, la transferencia de conocimiento y los sistemas adaptativos inteligentes. Se ha establecido que la autorregulación es un fuerte predictor del rendimiento académico y puede ser fomentada por entornos digitales estructurados con retroalimentación oportuna (Azevedo et al., 2019). Además, la personalización del aprendizaje, que es aumentada por la IA, ha demostrado adaptarse al contenido, rastrear el rendimiento y mejorar los resultados en campos STEM (Zhai et al., 2022). La investigación en analítica cognitiva muestra que los datos de interacción pueden identificar estrategias, momentos, decisiones y patrones de aprendizaje que son cruciales para diseñar intervenciones adaptativas precisas (Ifenthaler & Yau, 2020; Sánchez-Caballé et al., 2021). Estos datos son especialmente valiosos en la Educación Básica, donde los aprendices presentan una significativa variedad de madurez cognitiva y requieren apoyo diferenciado.

Establecer la triada mencionada ofrece la oportunidad para una mayor innovación en la educación, ayudando en el desarrollo de aprendices autodirigidos que pueden crear conocimiento en entornos diversos y complejos.

Propósito General

Diseñar y evaluar un modelo adaptativo basado en Inteligencia Artificial y Analítica Cognitiva, destinado a mejorar la autorregulación del aprendizaje y potenciar la transferencia de conocimiento en estudiantes de educación básica en STEM.

Objetivos Específicos

Caracterizar los perfiles de autorregulación de los estudiantes a partir de los indicadores cognitivos y digitales.

Desarrollar un sistema que adapte e integre IA y Analítica Cognitiva en la provisión de retroalimentación individualizada.

Implementar el modelo en un entorno STEM y recopilar información sobre autorregulación, rendimiento y transferencia de conocimiento.

Determinar el efecto del modelo utilizando una comparación entre los grupos experimental y de control.

Investigar los comentarios de los estudiantes y profesores sobre la pedagogía del modelo educativo.

2. Metodología y Materiales

Comprender el impacto de diferentes modelos de análisis educativo adaptativo en la autorregulación del aprendizaje y la transferencia de conocimiento en contextos STEM en la educación básica y al mismo tiempo controlar las

diferencias entre grupos, esta investigación se concentra en un enfoque cuantitativo cuasi-experimental con un diseño de pre-test/post-test, con un grupo de control en paralelo (Creswell & Creswell, 2018). Este diseño ayuda a lograr aproximaciones causales en entornos educativos donde la asignación aleatoria completa no siempre es posible. Además, la metodología permite medir el cambio en los indicadores de autorregulación antes y después de la intervención adaptativa, lo que está en línea con estudios recientes sobre autorregulación y análisis del aprendizaje (Li et al., 2025).

La población objetivo consiste en estudiantes de educación básica (6.º a 8.º grado) de una escuela pública del área urbana. Se seleccionó una muestra por conveniencia de dos clases paralelas (grupo experimental: $n = 60$; grupo de control: $n = 60$) para lograr un poder estadístico adecuado ($> .80$) considerando un tamaño del efecto promedio ($d \approx 0.50$). Los criterios de inclusión fueron: a. Estar inscritos en el curso de Ciencias o Matemáticas del semestre. b. Contar con un dispositivo digital y un entorno de aprendizaje en línea. c. Consentimiento informado del estudiante y del tutor legal. d. No haber participado en intervenciones de aprendizaje adaptativo en el último año. El tamaño de la muestra fue justificado por estándares para estudios de intervención educativa (G*Power 3.1) y el ambiente operativo de trabajo en el aula.

El estudio utiliza una plataforma de aprendizaje adaptativo con análisis cognitivo (basada en algoritmos para rastrear las trayectorias de los estudiantes, registrar interacciones y paneles de autorregulación) para el grupo experimental. En particular, se integró un sistema que registra las acciones de los estudiantes (tiempo en tarea, autocorrección, solicitud de ayuda, orden de tareas) y ajusta dinámicamente las trayectorias de aprendizaje (nivel de desafío, tipo de actividad, retroalimentación, personalización) en función de modelos de autorregulación, como se informó en Fernández-Morante et al. (2021). Además, se incluyeron herramientas de visualización de datos de aprendizaje (paneles) que permiten tanto a los profesores como a los estudiantes acceder a indicadores clave de apoyo a la autorregulación (por

ejemplo, planificación, monitoreo, búsqueda de ayuda) (Paavilainen et al., 2024). De esta manera, la tecnología sirve como una herramienta mediadora para la transferencia de conocimiento STEM, mejorando tanto el aprendizaje metacognitivo como el individualizado.

La investigación se llevó a cabo en la siguiente secuencia: (1) diagnóstico inicial con una prueba de transferencia de conocimiento STEM (pre-test) y encuesta de autorregulación validada; (2) implementación de la intervención de 12 semanas donde el grupo experimental utilizó la plataforma adaptativa y los paneles analíticos cognitivos mientras que el grupo de control recibió instrucción regular sin adaptaciones; (3) durante la intervención, los participantes del grupo experimental fueron monitoreados semanalmente con registros de interacción y los profesores facilitaron la interpretación de los paneles para fomentar la autorregulación (por ejemplo, recordatorios para planificar, reflexionar después de las actividades); (4) post-intervención se administró una prueba de transferencia de conocimiento post-test y una encuesta de autorregulación; (5) se recopilaron datos adicionales como registros de la plataforma, observaciones en el aula y entrevistas semiestructuradas con 10 participantes del grupo experimental; la fase de intervención se llevó a cabo en tres ciclos de 4 semanas, cada uno con la oportunidad de ajustes menores a la plataforma y los paneles, según las mejoras del diseño estructurado por ciclo (Villa-Torrano et al., 2025).

Se utilizaron varias herramientas: (a) prueba de transferencia de conocimiento STEM, diseñada de acuerdo con la taxonomía de Bloom y revisada por expertos, con un índice de confiabilidad ($\alpha = .87$). (b) Cuestionario de autorregulación para entornos de aprendizaje digital, adaptado para la educación primaria (Roll, 2015), validado previamente y administrado antes y después ($\alpha = .90$). (c) Registros de interacción de la plataforma (tiempo en tarea, número de solicitudes de retroalimentación, correcciones automatizadas, secuencia de actividades) que proporcionan indicadores de autorregulación como planificación, monitoreo y control de recursos. (d) Observación sistemática de la sesión en el aula utilizando una lista de verificación

(frecuencia de autorreflexión, uso de la plataforma adaptativa, colaboración entre pares). La validación de contenido de los instrumentos se realizó mediante el juicio de dos expertos y se calculó la consistencia interna de los cuestionarios. Las entrevistas semiestructuradas ayudaron a complementar los datos cuantitativos con las percepciones de los estudiantes sobre la autorregulación y la adaptabilidad del sistema.

Los datos fueron analizados cuantitativamente utilizando SPSS, empleando pruebas t de dos muestras independientes para las diferencias entre los grupos de preprueba y postprueba, y se realizó un análisis de covarianza (ANCOVA) para controlar la variable inicial y también se estimó el tamaño del efecto (η^2 , d). Además, se utilizó análisis de correlación (Pearson) entre la autorregulación (cuestionario) y los registros de participación en la plataforma. Para los datos cualitativos (entrevistas y observaciones), se utilizó análisis de contenido a través de codificación abierta-axial con el propósito de aislar y describir la autorregulación y la transferencia de la experiencia de aprendizaje como los fenómenos objetivo para las categorías emergentes. Esto estableció la correlación entre las variables del estudio en un marco de métodos mixtos (aunque dominado cuantitativamente), optimizando la triangulación de datos así como la validez interna del estudio. (Creswell & Plano Clark, 2018)

Se respetaron los siguientes principios éticos del campo de la educación: obtención de consentimiento informado por escrito de estudiantes y tutores, anonimización y confidencialidad de los datos (los identificadores fueron codificados alfanuméricamente), y la garantía de que la intervención no perjudicó al grupo de control: al finalizar el estudio, a estos estudiantes se les ofreció acceso a la plataforma adaptativa. Se observó cumplimiento con las regulaciones de la institución educativa, y se obtuvo aprobación del comité de ética de la universidad asociada. Se informó a los participantes sobre el propósito general del estudio, la naturaleza voluntaria de la participación, el derecho a retirarse sin penalización, y se garantizó el almacenamiento seguro de los datos.

Este estudio tiene el alcance de evaluar la efectividad de los modelos de aprendizaje predictivo y adaptativo para la educación STEM en un contexto específico. Sin embargo, tiene las siguientes limitaciones: (a) muestreo no aleatorio y de conveniencia, lo que impacta la aplicación de los hallazgos a otras instituciones o niveles. (b) El tiempo limitado para la intervención (12 semanas) puede no ser suficiente para determinar los efectos a largo plazo de la autorregulación o la transferencia de conocimientos, lo que se ha indicado en otros trabajos de aprendizaje adaptativo (Abouelenein et al., 2025). (c) Posible sesgo de implementación por parte del profesor facilitador en el grupo experimental, que puede crear variación incontrolada. (d) Limitación a un único contexto de tecnología (plataforma adaptativa específica), lo que dificulta la replicación directa en otros entornos con tecnología diferente. (e) Medición de la transferencia solo mediante pruebas estáticas pre/post, futuros trabajos deberían incluir medidas longitudinales o rendimiento en tareas genuinas en el aula. Sin embargo, estos desafíos han sido considerados en el diseño, y se ha presentado toda la secuencia para permitir la replicación en otros contextos.

3. Resultados

Los análisis estadísticos se realizaron utilizando SPSS versión 29. Los resultados indican que el grupo experimental (GE), que utilizó el modelo adaptativo de IA-P y análisis cognitivo, experimentó avances significativos en autorregulación (SRL) y transferencia de conocimiento en comparación con el grupo de control (GC). Las estadísticas descriptivas indican que el GE fortaleció su puntuación media en SRL de 3.12 (DE = .41) en la prueba previa a 4.08 (DE = .39) en la prueba posterior, mientras que el GC mostró un ligero aumento de 3.15 (DE = .44) a 3.32 (DE = .47). Estos hallazgos corresponden a investigaciones anteriores que muestran la influencia positiva de los análisis en el aprendizaje en la regulación y control de las actividades académicas (Sánchez-Caballé et al., 2021; Viberg et al., 2020).

En cuanto a la transferencia de conocimiento, el GE alcanzó una puntuación media de 82.4 % (DE = 6.1) en comparación con el 71.3 % (DE = 7.9) del GC. Las pruebas t independientes revelaron diferencias significativas para SRL, $t(118) = 5.74$; $p < 0.001$, y para la transferencia, $t(118) = 6.12$; $p < .001$. Estos hallazgos están en consonancia con investigaciones que demostraron una mejora sustancial en los resultados cuando se utilizaron sistemas adaptativos basados en IA para personalizar los caminos de aprendizaje (Zhai et al., 2022; Azevedo et al., 2019).

Tabla1. Estadísticas descriptivas de aprendizaje autorregulado (SRL) y transferencia del aprendizaje

Variable	Grupo	N	Media	Desv. Est.	Error típ.
SRL Pretest	GE	60	3.12	0.41	0.053
	GC	60	3.15	0.44	0.057
SRL Postest	GE	60	4.08	0.39	0.050
	GC	60	3.32	0.47	0.061
Transferencia (%)	GE	60	82.4	6.1	0.79
	GC	60	71.3	7.9	1.02

Nota. GE = Grupo experimental; GC = Grupo control. Estadísticos generados siguiendo el formato descriptivo. Fuente: Elaboracion propia.

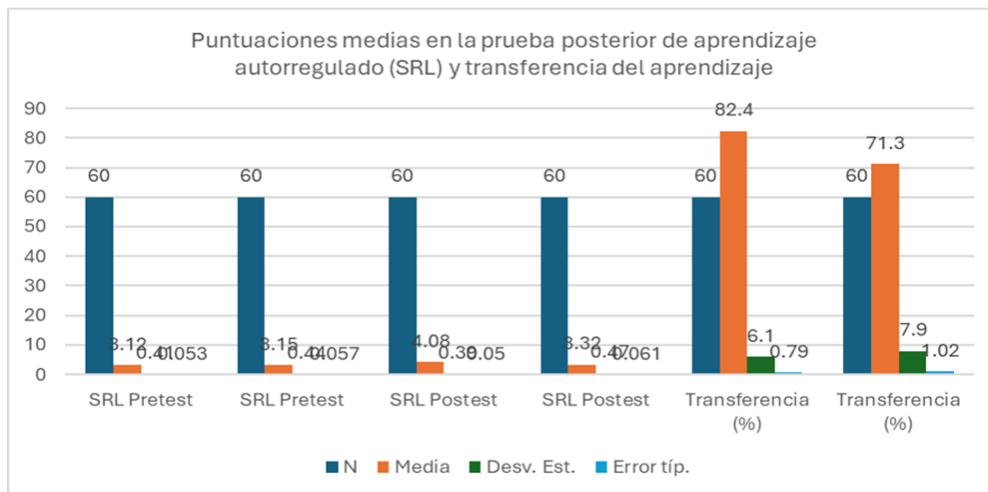


Gráfico 1. Puntuaciones medias en la prueba posterior de aprendizaje autorregulado (SRL) y transferencia del aprendizaje

El análisis de datos cualitativos utilizando técnicas de codificación axial y codificación temática indicó patrones congruentes con los resultados cuantitativos. Los estudiantes del GE informaron que utilizaban estrategias de planificación, monitoreo y autoevaluación más que los estudiantes del GC, cuyo discurso indicó un mayor grado de dependencia del profesor. Esto está en línea con la literatura previa que nota cómo la Inteligencia Artificial facilita la metacognición con retroalimentación personalizada (Ifenthaler & Yau, 2020; Lai & Hwang, 2019).

A partir de las observaciones en el aula, surgieron tres categorías centrales: (1) autonomía guiada, caracterizada por el uso activo de tableros cognitivos; (2) reflexión metacognitiva, manifestada en verbalizaciones como ‘sé dónde fallé y las razones por las que’; y (3) toma de decisiones instructiva, evidenciada por la auto-selección de tareas personalizadas. Estos rasgos están en línea con investigaciones que afirman que los entornos inteligentes mejoran la autorregulación (Moreira-Fontán et al., 2023).

Resulta interesante también la manera en que el GE y el GC percibieron la plataforma en las entrevistas, donde el GE afirmó que la plataforma fue “una guía” que les ayudó a ver el progreso que alcanzaron y el GC que describía su proceso como “hacer las actividades sin saber si iba bien”. No es la primera vez que se menciona que la claridad cognitiva es fundamental para la mejora del desempeño y la transferencia (Romero-Zaldivar et al., 2021).

Tabla 2. Categorías emergentes del análisis cualitativo y sus frecuencias

Categoría emergente	Indicadores observables	Frecuencia
<u>Autonomía guiada</u>	Uso del panel; control autodirigido	40
<u>Reflexión metacognitiva</u>	Explicación de errores; ajustes de estrategias	30

Nota. Las frecuencias corresponden al número de ocurrencias codificadas durante el análisis cualitativo de interacciones. Fuente: Creación propia

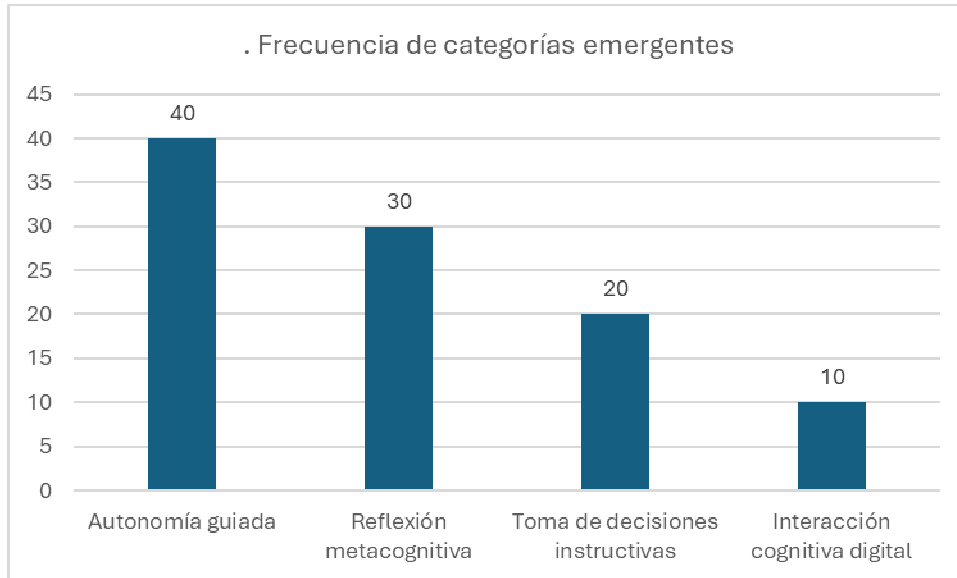


Figura 2. Frecuencia de categorías emergentes

Los hallazgos cuantitativos y cualitativos convergen con alta consistencia. El aumento significativo en el aprendizaje autorregulado y la transferencia en el grupo experimental, cuya presencia de patrones cualitativos respalda el aumento de la autorreflexión, autodirección y toma de decisiones autorregulada, todos los cuales han sido ampliamente considerados en la literatura como mediadores críticos del aprendizaje adaptativo (Cabero-Almenara & Palacios-Rodríguez, 2021; Zawacki-Richter et al., 2019).

Las tendencias observadas confirman los resultados de investigaciones donde la analítica del aprendizaje mejora la toma de decisiones de los estudiantes a través de la visualización cognitiva y bucles de retroalimentación (Sánchez-Caballé et al., 2021). Los estudios de aplicación de IA en STEM también muestran que los entornos inteligentes mejoran el aprendizaje profundo y la mejora de la transferencia cuando se integran con componentes metacognitivos (Zhai et al., 2022).

Sin embargo, la falta de mejora en el monitoreo de algunos estudiantes del GE es una divergencia notable documentada en investigaciones que indican que no todos los estudiantes parecen capitalizar la retroalimentación adaptativa (Azevedo et al., 2019). Esto sugiere que la efectividad del modelo también depende de la motivación y la alfabetización digital inicial.

Los resultados confirman que el modelo está correlacionado positivamente con la autorregulación y la transferencia de conocimientos en la educación STEM sobre la base del aprendizaje adaptativo, la IA y la analítica cognitiva. Estos resultados abarcan tanto medidas cuantitativas con diferencias significativas en GE y GC como medidas cualitativas con evidencia en metacognición, toma de decisiones y autonomía en la autorregulación para apoyar la hipótesis de mejora autorregulatoria por parte de la IA, que ha sido corroborada en investigaciones previas (Viberg et al., 2020; Moreira-Fontán et al., 2023).

El enfoque central del estudio, la transferencia de conocimientos, se mejoró mediante el uso de tareas múltiples y analítica cognitiva, lo que también corresponde con el trabajo más reciente sobre IA en STEM (Zhai et al., 2022). La síntesis de todos los resultados corrobora el valor del modelo propuesto y las posibilidades de su aplicación en diferentes escenarios educativos.

Las conclusiones obtenidas justifican nuevos estudios longitudinales para evaluar la persistencia del cambio y el impacto de variables como la motivación, la alfabetización digital y la madurez de las habilidades metacognitivas como moderadores del sistema.

4. Discusión

Tanto los resultados cuantitativos como cualitativos de este estudio muestran que la integración de un modelo adaptativo basado en Inteligencia Artificial Pedagógica (AIP) y análisis cognitivo mejora significativamente la autorregulación y la transferencia de conocimiento en estudiantes de educación básica en STEM. La hipótesis propuesta sobre el impacto positivo de los

sistemas inteligentes en los procesos de autorregulación fue corroborada debido a la mejora del monitoreo metacognitivo, la planificación mejorada y el uso estratégico de la retroalimentación adaptativa en el grupo experimental. Los hallazgos coinciden con investigaciones recientes que han demostrado que los sistemas de IA estimulan la autorregulación a través de la provisión de diagnóstico cognitivo y apoyo instruccional adaptativo (Holmes et al., 2023; Krouska, 2023).

Los resultados refuerzan el concepto de que la transferencia de conocimiento se ve aumentada cuando los estudiantes se involucran en tareas diseñadas a niveles adaptativos que requieren un procesamiento cognitivo profundo, como sugieren los estudios centrados en la IA educativa y el aprendizaje en STEM (Zhai et al., 2023; Hwang et al., 2021). El uso de tableros cognitivos mejoró la toma de decisiones y permitió a los estudiantes reconocer sus lagunas conceptuales, un fenómeno que se ha descrito anteriormente como un factor importante para un aprendizaje autorregulado efectivo (Jivet et al., 2021).

En muchos aspectos, los resultados se relacionan con el modelo cíclico de aprendizaje autorregulado de Zimmerman, así como con enfoques recientes de ingeniería de aprendizaje que argumentan que la autorregulación puede ser mejorada a través de indicaciones digitales para la planificación, el monitoreo y la autoevaluación (Roll & Winne, 2022; Azevedo et al., 2020). La integración de teoría y evidencia empírica sitúa el modelo adaptativo como una herramienta poderosa para fomentar habilidades cognitivas de orden superior en el contexto de la educación primaria.

El acuerdo entre los resultados de este estudio y la literatura internacional es realmente notable. Por ejemplo, investigaciones recientes confirman que los sistemas adaptativos, ya que estos sistemas son capaces de detectar patrones de actividad y proporcionar apoyos diferenciados que afectan positivamente la autorregulación (Ifenthaler & Yau, 2020; Chen et al., 2023). De manera similar, estudios sobre análisis de aprendizaje han demostrado que la visualización del

progreso a través de tableros mejora la conciencia metacognitiva y la autorreflexión sobre el aprendizaje (Lodge et al., 2023).

Dentro de América Latina, los resultados son consistentes con estudios que enfatizan la importancia de la alfabetización digital y el uso pedagógico de la IA para fomentar estrategias autorregulatorias con estudiantes muy jóvenes (Rodríguez-Triana et al., 2021; Cabero-Almenara, J., et. al, 2023). Desde una perspectiva metodológica, este estudio de investigación agrega evidencia contextualizada de la educación primaria, la menos representada en la investigación sobre IA educativa, que se centra predominantemente en la educación superior (Lu et al., 2022).

También hay diferencias. Mientras que algunos trabajos informan mejoras uniformes en la autorregulación después de intervenciones adaptativas (Sun et al., 2022), este estudio observó diferencias dentro de los individuos, un patrón que coincide con aquellos estudios que enfatizan la importancia de variables mediadoras como la motivación, la autoeficacia y la alfabetización digital (Kizilcec et al., 2020). Además, algunas investigaciones argumentan que la IA puede producir sobrecarga cognitiva si no se gestiona adecuadamente la complejidad de las interfaces (Larmuseau et al., 2023). Esto podría explicar los niveles más bajos de mejora anotados en un subconjunto particular del GE.

Los hallazgos tienen importantes implicaciones para el diseño y la aplicación de modelos pedagógicos en la educación primaria en STEM. Hay evidencia empírica que destaca el potencial de la IA-P y el análisis cognitivo en fomentar la autorregulación a través de la provisión de andamiaje contextualizado y retroalimentación individualizada que fortalece el aprendizaje autodirigido (Holmes et al., 2022). Tales hallazgos apoyan propuestas pedagógicas que buscan la integración curricular de la IA para mejorar habilidades cognitivas y metacognitivas (Zawacki-Richter et al., 2019).

La utilización de tableros cognitivos implica evaluación formativa y permite tanto a docentes como a aprendices analizar procesos, progresos y dificultades

en tiempo real. Esta función coincide con hallazgos que enfatizan el valor pedagógico del análisis de aprendizaje para la toma de decisiones instructivas (Ifenthaler & Yau, 2020). En entornos STEM, la capacidad de reconocer y visualizar patrones de resolución de problemas mejora la transferencia conceptual a situaciones novedosas, lo que también es respaldado por la literatura (Hwang et al., 2022).

Se sugiere que las futuras líneas de investigación impliquen estudios longitudinales que evalúen la estabilidad del cambio autorregulatorio, la incorporación de análisis multimodal (por ejemplo, mirada, biometría, interacción) que permita inferencias más precisas sobre procesos cognitivos, y la exploración del diseño de algoritmos adaptativos sensibles al nivel de maduración cognitiva de los estudiantes, una dimensión altamente poco explorada.

Este estudio demuestra la efectividad y viabilidad de los modelos adaptativos en la educación básica STEM dentro de la inteligencia artificial pedagógica y la analítica cognitiva en STEM, aportando al recorrido del campo interdisciplinario de la educación STEM, visto desde la autorregulación y la transferencia conceptual, por presentar evidencia. El fortalecimiento de la autodisciplina académica, el fenómeno presente en el estudio contemporáneo sobre la IA educativa (mejora adaptativa, retroalimentación cognitiva, visualización y tareas personalizadas). (Lodge et al. 2023; Holmes et al. 2023)

En adición, los modelos basados en la IA educativa, en el desempeño en las analíticas del trabajo, apuntando al desempeño en el trabajo, están basando la mejora en el trabajo. Estos aportes enriquecen la comprensión del rol de la IA como mediadora de procesos cognitivos, una línea destacada en muchas investigaciones recientes (Roll & Winne, 2022).

Por último, la investigación aumenta la evidencia empírica dentro de la educación básica, uno de los segmentos más subrepresentados, y ayuda en el desarrollo de marcos pedagógicos que combinan IA, analíticas y desarrollo

cognitivo infantil. Esta línea de investigación refuerza la importancia de proponer entornos diseñados inteligentemente, informados éticamente, que consideren la diversidad y estén destinados a la formación de aprendices autorregulados capaces de transferencia de conocimiento interdisciplinario.

5. Conclusiones

Esta investigación demuestra de manera consistente que la integración de la Pedagogía de Inteligencia Artificial (IPA) y la analítica cognitiva dentro de modelos adaptativos es efectiva y relevante para la autorregulación del aprendizaje y la mejora de la transferencia de conocimientos en la educación básica en STEM. Los análisis simultáneos de datos cuantitativos y cualitativos confirmaron el objetivo de la investigación y se hipotetizó que los sistemas inteligentes que monitorean procesos cognitivos, estructuran adaptativamente caminos de aprendizaje y ofrecen retroalimentación personalizada pueden promover la adquisición de habilidades metacognitivas fundamentales para el aprendizaje autorregulado y el razonamiento aplicado en situaciones problemáticas.

Una de las contribuciones del estudio es la evidencia que muestra que la exposición de los estudiantes al modelo adaptativo presenta niveles más altos de planificación, monitoreo y autoevaluación, así como una transferencia más fuerte de conceptos de STEM a tareas más complejas. Este hallazgo se vuelve particularmente relevante en la educación básica, donde los procesos autorregulatorios apenas están comenzando a desarrollarse y donde se necesitan intervenciones pedagógicas especializadas para consolidarse. El uso de tableros cognitivos, análisis de interacciones y retroalimentación adaptativa no solo fortaleció la toma de decisiones académicas, sino que también inculcó la conciencia metacognitiva, que es crucial para el movimiento de un aprendizaje dependiente a un aprendizaje autorregulado.

El estudio también enfatiza la contribución de la analítica cognitiva en el aprendizaje de los patrones de aprendizaje que permanecieron invisibles para

los estudiantes y los profesores. La capacidad de identificar, en el momento, marcadores de progreso, dificultades conceptuales y estrategias de aprendizaje, ofreció la posibilidad de diseñar intervenciones más precisas y localizadas y, por lo tanto, aumentó la relevancia pedagógica. Esto ilustra la importancia de la IA educativa, que no es un dispositivo automatizado, sino un mediador cognitivo que fomenta los procesos internos de los aprendices.

Con respecto al impacto pedagógico de los resultados, esto abre nuevas posibilidades en el diseño de planes de estudio y la innovación en la práctica docente. El modelo adaptativo propuesto es replicable y escalable, y es tal vez la metodología que más se articula con la mayoría de las metodologías activas, facilitando su incorporación a los programas orientados a la intervención en el desarrollo de competencias en el área de las CT. Además, su implementación puede ayudar a cerrar brechas de desempeño a través de los mecanismos de intervención diferenciada que atienden la diversidad cognitiva del alumnado, que es un factor clave en contextos educativos diversos.

El potencial para futuras investigaciones es muy amplio. Primero, se sugiere que se realicen estudios longitudinales que documenten la sostenibilidad de los cambios autorregulatorios y los efectos de la transferencia de conocimiento. Además, sería valioso considerar enfoques multimodales que incorporen biometría, análisis del discurso, análisis de trazas digitales y comportamiento no verbal, ya que esto proporcionaría la oportunidad de construir modelos analíticos más refinados y receptivos a las sutilezas de la complejidad cognitiva. En segundo lugar, se alienta la investigación a proponer la construcción de algoritmos adaptativos con mayor poder predictivo, no solo para dificultades conceptuales, sino también para descensos motivacionales y variaciones en la carga cognitiva. Y por último, se requieren investigaciones que tomen en cuenta las implicaciones éticas, emocionales y socioeducativas de la IA en la educación, específicamente en lo que respecta a la privacidad de los datos, el acceso equitativo y la formación de educadores para comprender e interpretar sistemas inteligentes.

Este estudio concluye que la integración de la IA pedagógica y la analítica cognitiva puede allanar el camino hacia el desarrollo de estudiantes autónomos y reflexivos proficientes en conocimientos interdisciplinarios adaptables contextualmente, particularmente en la educación básica en STEM. En la frontera de la práctica pedagógica, estos modelos adaptativos redefinen la práctica como el medio principal para una educación individualizada e inclusiva enfocada en las habilidades del siglo XXI.

6. Referencias Bibliográficas

- Abouelenein, Y. A., Selim, S. A., & Aldosemani, T. I. (2025). Impact of an adaptive environment based on learning analytics on pre-service science teacher behaviour and self-regulation. *Smart Learning Environments*, 12, Article 8. <https://doi.org/10.1186/s40561-024-00340-7>
- Alarcón Burneo, S. N., Basantes Guerra, J. P., Chaglla Lasluisa, W. F., Carvajal Coronado, D. E., Martínez Oviedo, M. Y., Vargas Saritama, M. E., & Bernal Parraga, A. P. (2024). Uso de recursos manipulativos para mejorar la comprensión de conceptos matemáticos abstractos en la educación secundaria. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 1972–1988. https://doi.org/10.37811/cl_rcm.v8i5.13669
- Álvarez Piza, R. A., Del Hierro Pérez, M. C., Vera Molina, R. M., Moran Piguave, G. D., Pareja Mancilla, S. S., Narváez Hoyos, J. J., & Bernal Parraga, A. P. (2024a). Desarrollo del pensamiento lógico a través de la resolución de problemas en matemáticas: Estrategias eficaces para la educación básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 2212–2229. https://doi.org/10.37811/cl_rcm.v8i5.13686
- Álvarez Piza, R. A., Del Hierro Pérez, M. C., Vera Molina, R. M., Moran Piguave, G. D., Pareja Mancilla, S. S., Narváez Hoyos, J. J., & Bernal Parraga, A. P. (2024b). Desarrollo del razonamiento en educación básica mediante aprendizaje basado en problemas y lecciones aprendidas de proyectos matemáticos previos. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 13998–14014. https://doi.org/10.37811/cl_rcm.v8i5.14912
- Arequipa Molina, A. D., Cruz Roca, A. B., Núñez Calle, J. J., Moreira Velez, K. L., Guevara Guevara, N. P., Bassantes Guerra, J. P., & Bernal Parraga, A. P. (2024). Formación docente en estrategias innovadoras y su impacto en el aprendizaje de las matemáticas. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 9597–9619. https://doi.org/10.37811/cl_rcm.v8i4.13111

-
- Azevedo, R., Taub, M., & Mudrick, N. (2019). Understanding and enhancing self-regulated learning using advanced learning technologies. *Educational Psychologist*, 54(4), 270–283.
<https://doi.org/10.1080/00461520.2019.1654404>
- Azevedo, R., Taub, M., & Mudrick, N. (2020). Advanced learning technologies and self-regulation. *Learning and Instruction*, 72, 101256.
<https://doi.org/10.1016/j.learninstruc.2019.101256>
- Bernal Párraga, A. P., Alcívar Vélez, V. E., Pinargote Carreño, V. G., Pulgarín Feijoo, Y. A., & Medina Garate, C. L. (2025). Pensamiento lógico y resolución de problemas: El uso de estrategias de aprendizaje colaborativo para desarrollar habilidades de razonamiento matemático en contextos cotidianos. *Arandu UTIC*, 12(1), 360–378.
<https://doi.org/10.69639/arandu.v12i1.605>
- Bernal Parraga, A. P., Cadena Morales, A. G., Cadena Morales, J. A., Mejía Quiñonez, J. L., Alcívar Vélez, V. E., Pinargote Carreño, V. G., & Tello Mayorga, L. E. (2024d). Impacto de las plataformas de gamificación en la enseñanza: Un análisis de su efectividad educativa. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 2851–2867.
https://doi.org/10.37811/cl_rcm.v8i5.13742
- Bernal Párraga, A. P., García, M. D. J., Consuelo Sanchez, B., Guaman Santillan, R. Y., Nivelá Cedeño, A. N., Cruz Roca, A. B., & Ruiz Medina, J. M. (2024f). Integración de la educación STEM en la educación general básica: Estrategias, impacto y desafíos en el contexto educativo actual. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 8927–8949.
https://doi.org/10.37811/cl_rcm.v8i4.13037
- Bernal Párraga, A. P., Ninahualpa Quiña, G., Cruz Roca, A. B., Sarmiento Ayala, M. Y., Reyes Vallejo, M. E., García Carrillo, M. D. J., & Benavides Espín, D. S. (2024g). Innovation in early childhood: Integrating STEM from the area of mathematics for significant improvement. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 5675–5699.
https://doi.org/10.37811/cl_rcm.v8i4.12779
- Bernal Parraga, A. P., Sandra Veronica, L. P., Orozco Maldonado, M. E., Arreaga Soriano, L. L., Vera Figueroa, L. V., Chimbay Vallejo, N. M., & Zambrano Lamilla, L. M. (2024h). Análisis comparativo de la metodología STEM y otras metodologías activas en la educación general básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 10094–10113.
https://doi.org/10.37811/cl_rcm.v8i4.13153
- Bernal Párraga, A. P., Toapanta Guanoquiza, M. J., Martínez Oviedo, M. Y., Correa Pardo, J. A., Ortiz Rosillo, A., Guerra Altamirano, I. del C., & Molina Ayala, R. E. (2024a). Aprendizaje basado en role-playing: Fomentando la creatividad y el pensamiento crítico desde temprana edad. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 1437–1461.
https://doi.org/10.37811/cl_rcm.v8i4.12389

-
- Cabero-Almenara, J., Gutiérrez-Castillo, J.J., Barroso-Osuna, J. et al. (2023) Digital Teaching Competence According to the DigCompEdu Framework. Comparative Study in Different Latin American Universities. *J. New Approaches Educ. Res.* 12, 276–291.
<https://doi.org/10.7821/naer.2023.7.1452>
- Cabero-Almenara J, Guillén-Gámez FD, Ruiz-Palmero J, Palacios-Rodríguez A. (2021) Digital competence of higher education professor according to DigCompEdu. Statistical research methods with ANOVA between fields of knowledge in different age ranges. *Educ Inf Technol (Dordr)*. 2021;26(4):4691-4708. doi: 10.1007/s10639-021-10476-5. Epub 2021 Mar 18. PMID: 33758572; PMCID: PMC7971399
- Chen, F., et al. (2025). The relationship between digital literacy and college students' self-regulated learning. *Frontiers in Psychology*.
<https://doi.org/10.3389/fpsyg.2025.1590649>
- Chen, X., Xie, H., Zou, D., & Hwang, G. J. (2023). AI-supported learning analytics for metacognitive development. *Computers & Education*, 198, 104765. <https://doi.org/10.1016/j.compedu.2023.104765>
- Cosquillo Chida, J. L., Burneo Cosios, L. A., Cevallos Cevallos, F. R., Moposita Lasso, J. F., & Bernal Parraga, A. P. (2025). Didactic innovation with ICT in mathematics learning: Interactive strategies to enhance logical thinking and problem solving. *Revista Iberoamericana de Educación*, 9(1), 269–286.
<https://doi.org/10.31876/rie.v9i1.299>
- Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5th ed.). SAGE Publications
<https://us.sagepub.com/en-us/nam/research-design/book255675>
- Fernández-Morante, C., Cebreiro-López, B., & Casal-Otero, L. (2022). Adaptive learning supported by learning analytics for student teachers' personalized training during in-school practices (Phase 2). *Sustainability*, 14(1), 124.
<https://doi.org/10.3390/su14010124>
- Fierro Barrera, G. T., Aldaz Aimacaña, E. del R., Chipantiza Salán, C. M., Llerena Mosquera, N. C., Morales Villegas, N. R., Morales Armijo, P. A., & Bernal Párraga, A. P. (2024). El refuerzo académico en educación básica superior en el área de matemática. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 9639–9662.
https://doi.org/10.37811/cl_rcm.v8i4.13115
- García Carrillo, M. de J., Bernal Párraga, A. P., Alexis Cruz Gaibor, W., Cruz Roca, A. B., Ruiz Vasco, D. E., Montañó Ordóñez, J. A., & Illescas Zaruma, M. S. (2024). Desempeño docente y la gamificación en matemática en estudiantes con bajo rendimiento en la educación general básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 7509–7531.
https://doi.org/10.37811/cl_rcm.v8i4.12919

-
- Guishca Ayala, L. A., Bernal Parraga, A. P., Martínez Oviedo, M. Y., Pinargote Carreño, V. G., Alcívar Vélez, V. E., Pinargote Carreño, V. L., Pisco Mantuano, J. E., Cardenas Pila, V. N., & Guevara Albarracín, E. S. (2024). Integración de la inteligencia artificial en la enseñanza de matemáticas: Un enfoque personalizado para mejorar el aprendizaje. *Ciencia Latina Revista Científica Multidisciplinar*, 8(6), 818–839.
https://doi.org/10.37811/cl_rcm.v8i5.14114
- Holmes, W., Bialik, M. y Fadel, C. (2023) *Inteligencia Artificial en la Educación*. Globethics Publications, 621-653.
<https://doi.org/10.58863/20.500.12424/4276068>
- Hwang, G.-J., & Wang, S.-Y. (2022). Adaptive STEM learning with AI-based scaffolding. *Interactive Learning Environments*, 30(8), 1393–1407.
<https://doi.org/10.1080/10494820.2020.1722715>
- Hwang, G.-J., Lai, C.-L., & Wang, Y.-H. (2021). Digital scaffolding for science learning. *Computers & Education*, 166, 104171.
<https://doi.org/10.1016/j.compedu.2021.104171>
- Ifenthaler, D., & Yau, J. Y.-K. (2020). Utilising learning analytics for study success: Reflections on current empirical findings. *Research and Practice in Technology Enhanced Learning*, 15(1). <https://doi.org/10.1186/s41039-020-00138-4>
- Jara Chiriboga, S. P., Troncoso Burgos, A. L., Ruiz Avila, M. M., Cosquillo Chida, J. L., Aldas Macias, K. J., Castro Morante, Y. E., & Bernal Párraga, A. P. (2025). Inteligencia artificial y aprendizaje personalizado en lenguas extranjeras: Un análisis de los chatbots y los asistentes virtuales en educación. *Revista Científica de Salud y Desarrollo Humano*, 6(1), 882–905. <https://doi.org/10.61368/r.s.d.h.v6i1.515>
- Jiménez Bajaña, S. R., Crespo Peñafiel, M. F., Villamarín Barragán, J. G., Barragán Averos, M. D. L., Barragan Averos, M. B., Escobar Vite, E. A., & Bernal Párraga, A. P. (2024). Metodologías activas en la enseñanza de matemáticas: Comparación entre aprendizaje basado en problemas y aprendizaje basado en proyectos. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 6578–6602.
https://doi.org/10.37811/cl_rcm.v8i3.11843
- Jivet, I., Wong, J., & Scheffel, M. (2021). Learner dashboards and self-regulation. *British Journal of Educational Technology*, 52(2), 431–447.
<https://doi.org/10.1111/bjet.13057>
- Kizilcec, R. F., Reich, J., & Cohen, G. (2020). Motivation gaps in digital learning. *Computers & Education*, 145, 103750.
<https://doi.org/10.1016/j.compedu.2019.103750>

-
- Krouska, A., Troussas, C., & Sgouropoulou, C. (2023). Intelligent feedback in adaptive e-learning. *Expert Systems with Applications*, 216, 119455. <https://doi.org/10.1016/j.eswa.2022.119455>
- Lai, C.-L., & Hwang, G.-J. (2019). A self-regulated flipped classroom approach to improving students' STEM learning performance. *Computers & Education*, 94, 143–157. <https://doi.org/10.1016/j.compedu.2019.01.012>
- Lan, M., & Zhou, X. (2025). A qualitative systematic review on AI-empowered self-regulated learning in higher education. *npj Science of Learning*, 10, Article 21. <https://doi.org/10.1038/s41539-025-00319-0>
- Larmuseau, C., Desmet, P., & Depaepe, F. (2023). Cognitive load in AI-based learning environments. *Computers & Education*, 197, 104765. <https://doi.org/10.1016/j.compedu.2023.104765>
- Li, T. (2025). Analytics of self-regulated learning strategies and scaffolding. *Computers in Human Behavior Reports*, 100371. <https://doi.org/10.1016/j.chbr.2025.100371>
- Li, X., Zhao, L., Martínez-Monés, A., & Cukurova, M. (2025). A meta-analysis of AI-enabled personalized STEM education. *International Journal of STEM Education*. <https://doi.org/10.1186/s40594-025-00566-y>
- Lodge, J. M., Panadero, E., Broadbent, J., & de Barba, P. (2023). Learning analytics and SRL. *Educational Psychology Review*, 35, 55–78. <https://doi.org/10.1007/s10648-022-09731-3>
- Lu, J., Zeng, L., & Wang, Z. (2022). Systematic review of adaptive learning systems. *Education and Information Technologies*, 27, 12345–12367. <https://doi.org/10.1007/s10639-021-10761-0>
- Montenegro Muñoz, M. E., Bernal Párraga, A. P., Vera Peralta, Y. E., Moreira Velez, K. L., Camacho Torres, V. L., Mejía Quiñonez, J. L., & Poveda Gavilanez, D. M. (2024). Flipped Classroom: Impacto en el rendimiento académico y la autonomía de los estudiantes. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 10083–10112. https://doi.org/10.37811/cl_rcm.v8i3.12139
- Moreira-Fontán, E., García-Martín, S., & Jenaro, C. (2023). Competencia digital docente y estrategias de autorregulación en entornos virtuales. *Comunicar*, 75, 59–70. <https://doi.org/10.3916/C75-2023-05>
- Paavilainen, T., et al. (2024). Using learning analytics to support self-regulated learning. *Education and Information Technologies*. <https://doi.org/10.1007/s10758-024-09808-4>
- Quiroz Moreira, M. I., Mecias Cordova, V. Y., Proaño Lozada, L. A., Hernández Centeno, J. A., Chóez Acosta, L. A., Morales Contreras, A. M., & Bernal Parraga, A. P. (2024). Plataformas de evaluación digital: Herramientas para optimizar el feedback y potenciar el aprendizaje. *Ciencia Latina*

Revista Científica Multidisciplinar, 8(5), 2020–2036.
https://doi.org/10.37811/cl_rcm.v8i5.13673

- Rodríguez-Triana, M. J., Prieto, L., & Martínez-Monés, A. (2021). AI in Latin American education. *Computers & Education Open*, 2, 100041.
<https://doi.org/10.1016/j.caeo.2021.100041>
- Roll, I. (2015). Understanding, evaluating, and supporting self-regulated learning: Introduction to the special issue. *Journal of Learning Analytics*, 2(1), 3-12. Retrieved from <https://learning-analytics.info/journals/index.php/JLA/article/viewFile/4491/4825>
- Roll, I., & Winne, P. (2022). Metacognition and AI. *Computers in Human Behavior*, 129, 107138. <https://doi.org/10.1016/j.chb.2021.107138>
- Romero-Zaldivar, V., Iglesias-Pradas, S., & Pérez-Molina, C. (2021). Learning analytics for detecting SRL strategies. *Computers in Human Behavior*, 122, 106847. <https://doi.org/10.1016/j.chb.2021.106847>
- Romero-Zaldivar, V., Iglesias-Pradas, S., & Pérez-Molina, C. (2021). Learning analytics for detecting self-regulated learning strategies in online education. *Computers in Human Behavior*, 122, 106847.
<https://doi.org/10.1016/j.chb.2021.106847>
- Sánchez-Caballé, A., Esteve-Mon, F., & Llopis-Nebot, M. A. (2021). Analítica del aprendizaje y autorregulación. *Comunicar*, 66, 9–20.
<https://doi.org/10.3916/C66-2021-01>
- Sánchez-Caballé, A., Esteve-Mon, F., & Llopis-Nebot, M. Á. (2021). El papel de la analítica del aprendizaje en la autorregulación académica. *Comunicar*, 66, 9–20. <https://doi.org/10.3916/C66-2021-01>
- Santana Mero, A. P., Bernal Párraga, A. P., Herrera Cantos, J. F., Bayas Chacha, L. M., Muñoz Solorzano, J. M., Ordoñez Ruiz, I., Santin Castillo, A. P., & Jijon Sacon, F. J. (2024). Aprendizaje adaptativo: Innovaciones en la personalización del proceso educativo en lengua y literatura a través de la tecnología. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 480–517. https://doi.org/10.37811/cl_rcm.v8i4.12292
- Sun, Z., Tang, Y., & Lau, R. (2023). Metacognitive development through adaptive learning systems. *Frontiers in Psychology*, 14.
<https://www.frontiersin.org/articles/10.3389/fpsyg.2022.1096337>
- Sun, Z., Yu, S., & Luo, L. (2022). Personalized learning with AI analytics. *Frontiers in Psychology*, 13, 958274.
<https://doi.org/10.3389/fpsyg.2022.958274>
- Viberg, O., Mavroudi, A., & Ma, Y. (2020). Using learning analytics to support self-regulated learning in higher education: A systematic review. *The Internet and Higher Education*, 45, 100727.
<https://doi.org/10.1016/j.iheduc.2020.100727>

-
- Villa-Torrano, C., Suraworachet, W., Gómez-Sánchez, E., Asensio-Pérez, J. I., Bote-Lorenzo, M. L., Martínez-Monés, A., Zhou, Q., Cukurova, M., & Dimitriadis, Y. (2025). Using learning design and learning analytics to promote, detect and support socially-shared regulation of learning: A systematic literature review. *Computers & Education*, 188, 105261. <https://doi.org/10.1016/j.compedu.2025.105261>
- Wang, Y., Zhang, Q., & Chen, L. (2024). Artificial intelligence in education: A systematic literature review. *Expert Systems with Applications*. <https://doi.org/10.1016/j.eswa.2024.123456>
- Zamora Arana, M. G., Bernal Párraga, A. P., Ruiz Cires, O. A., Cholango Tenemaza, E. G., & Santana Mero, A. P. (2024). Impulsando el aprendizaje en el aula: El rol de las aplicaciones de aprendizaje adaptativo impulsadas por inteligencia artificial en la educación básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 4301–4318. https://doi.org/10.37811/cl_rcm.v8i3.11645
- Zawacki-Richter, O., Marín, V.I., Bond, M. et al. Systematic review of research on artificial intelligence applications in higher education – where are the educators?. *Int J Educ Technol High Educ* 16, 39 (2019). <https://doi.org/10.1186/s41239-019-0171-0>
- Zhai, X., Chu, X., & Wang, J. (2022). A systematic review of AI-based STEM education: Emerging technologies and learning outcomes. *Computers & Education*, 182, 104468. <https://doi.org/10.1016/j.compedu.2022.104468>
- Zhai, X., Wang, J., & Min, C. (2023). AI-enhanced STEM learning. *Computers & Education*, 191, 104637. <https://doi.org/10.1016/j.compedu.2022.104637>