



Doi: <https://doi.org/10.70577/ASCE/311.332/2025>

Recibido: 2025-05-09

Aceptado: 2025-06-09

Publicado: 2025-07-11

Aprendizaje Matemático personalizado mediante inteligencia artificial: un modelo adaptativo para el desarrollo del razonamiento algebraico en educación

Personalized Mathematical Learning Using Artificial Intelligence: An Adaptive Model for the Development of Algebraic Reasoning in Education

Autor:

Violeta del Carmen Delgado Santin
violeta.delgado@educacion.gob.ec
<https://orcid.org/0009-0002-6679-4942>
Ministerio de Educación del Ecuador
Guayaquil-Ecuador

Milton Luyely Intriago Cedeño
milton.intriagolc@gmail.com
<https://orcid.org/0009-0009-2864-133X>
Universidad Tecnológica Empresarial de Guayaquil
Guayaquil-Ecuador

Jennifer Alejandra Intriago Moreira
jealeinmor@gmail.com
<https://orcid.org/0009-0001-5556-6787>
Instituto Superior Tecnológico FARO
Manta-Ecuador

Christian Eduardo González Ramírez
gonzalezcer18@gmail.com
<https://orcid.org/0009-0009-2601-8229>
Independiente
Guayaquil-Ecuador

Patricia del Pilar Tandayamo Vargas
patricia.tandayamo@educacion.gob.ec
<https://orcid.org/0009-0006-5939-4819>
Ministerio de Educación del Ecuador
Machala-Ecuador

Cómo citar

Delgado Santin, V. del C., Intriago Cedeño, M. L., Intriago Moreira, J. A., González Ramírez, C. E., & Tandayamo Vargas, P. del P. (2025). Aprendizaje Matemático personalizado mediante inteligencia artificial: un modelo adaptativo para el desarrollo del razonamiento algebraico en educación. *ASCE*, 4(3), 311–332.



Resumen

El presente trabajo busca crear, implementar y evaluar un modelo adaptativo de aprendizaje matemático personalizado utilizando inteligencia artificial (IA) que propicie las habilidades de razonamiento algebraico en estudiantes de secundaria. Esta investigación se plantea en respuesta a la importancia que reviste atender las deficiencias que los enfoques tradicionales han anclado en la algebra; en la mayoría de los casos se ignora las consideraciones de las diferencias individuales en los estilos de aprendizaje y niveles de comprensión de los estudiantes. En consecuencia, se diseñó un sistema inteligente que fusiona algoritmos de machine learning y minería de datos educativos para diagnosticar en tiempo real las habilidades cognitivas del estudiante y, por tanto, los recursos requeridos para el aprendizaje activo y autoorganizado se dispongan de forma flexible y ajustable. Con un enfoque mixto, esta investigación utilizó un diseño cuasi-experimental con un pretest-postest en grupo control con análisis cualitativo de interacciones dentro de la plataforma como complemento. La muestra estuvo compuesta por 240 estudiantes de tres colegios públicos que participaron en grupos experimentales y grupos de control. El sistema adaptativo fue llevado a cabo en el contexto de clases regulares de matemáticas durante un periodo de ocho semanas. Se aplicaron instrumentos validados para evaluar el avance en razonamiento algebraico, así como cuestionarios de percepción del aprendizaje personalizado en su experiencia. El desempeño algebraico del grupo experimental, en comparación con el grupo de control, mostró un progreso estadísticamente significativo dentro los límites determinados por la confianza ($p < 0.01$). El avance se notó en la generalización con simbolización y resolución de ecuaciones. El análisis también mostró que la motivación intrínseca así como la autopercepción de habilidad en matemáticas incrementaron en estudiantes que aprendieron en un entorno adaptativo. La motivación intrínseca así como la autopercepción de habilidad en matemáticas incrementaron en estudiantes que aprendieron en un entorno adaptativo. El análisis cualitativo mostró que existían interacciones con el sistema que refinaban las reglas de adaptación y feedback del modelo. Este estudio pone de manifiesto el poder que los modelos de IA personalizados tienen en la enseñanza del álgebra, al facilitar un aprendizaje más equitativo y eficaz. Se considera que el uso de la inteligencia artificial en el aula no solo facilita el abordaje de la diversidad cognitiva en el aula, sino que también permite el desarrollo del pensamiento algebraico de forma más sistemática y contextualizada.

Palabras clave: Aprendizaje, Inteligencia Artificial, Razonamiento Algebraico, Modelo Adaptativo, Educación, Matemáticas.



Abstract

The goal of this study is to use Artificial Intelligence (AI) to create, deploy, and assess an adaptive model for individualized math learning that will help high school pupils improve their algebraic reasoning skills. The study answers to the urgent need to fix the problems that traditional methods have caused in teaching algebra. These methods often don't take into account how different students learn and how well they understand the material. To do this, an intelligent system was made that uses machine learning algorithms and educational data mining to figure out how smart kids are in real time. As a result, the tools needed for active and self-directed learning are made available in a way that may be changed and adapted. The study used a quasi-experimental design with a pretest-posttest control group and a mixed-methods approach. It also looked at how people interacted with the platform in a qualitative way. There were 240 pupils in the sample, all from three public schools. They were split into two groups: experimental and control. The adaptive approach was used in ordinary math courses for eight weeks. We employed validated tools to measure progress in algebraic reasoning and perception surveys that focused on the individualized learning experience. The experimental group did significantly better at algebra than the control group, with a confidence level of $p < 0.01$. There was a big improvement in generalization through symbolization and solving equations. The study also showed that students who used the adaptive learning environment had more internal motivation and a better sense of their own math skills. Qualitative results showed that using the system helped improve the model's adaption rules and feedback systems. This study shows that individualized AI-based models could be useful in teaching mathematics, making learning more fair and effective. It suggests that using AI in the classroom not only helps with cognitive variety but also helps students learn algebraic thinking in a more structured and relevant way.

Keywords: Personalized learning, artificial intelligence, algebraic reasoning, adaptive modeling, secondary education, educational data mining, mathematics education.



Introducción

1.1 Contextualización del Tema

El rápido desarrollo de la inteligencia artificial (IA) en educación ha hecho posible crear modelos de aprendizaje que se personalizan según las capacidades cognitivas, los ritmos y las necesidades únicas de cada alumno, tales como las brechas en conocimiento o las preferencias sensoriales (Mustfa & Ashiq, 2024). Precisamente, el aprendizaje de las matemáticas ha sido uno de los áreas donde se han aprovechado con más ahínco estas tecnologías, dadas su lógica interna y los patrones que se repiten con frecuencia en su enseñanza (Carpio-Camacho et al., 2024). En el campo del álgebra, el uso de sistemas adaptativos ha probado su efectividad para el tratamiento de problemas de razonamiento en la poca específicos, lo que facilita un mejor diagnóstico y tratamiento pedagógico (Otero et al., 2024) así como control durante la enseñanza automatizada del feedback, lo que incrementa la comprensión y la autonomía del aprendiz (Hwang & Tu, 2021).

2. Revisión de antecedentes

Diversas investigaciones han documentado los beneficios del uso de IA en entornos de aprendizaje personalizado:

Mustfa y Ashiq (2024) evidenciaron mejoras sustanciales en el rendimiento estudiantil, así como en la motivación utilizando sistemas inteligentes adaptativos.

Loebis y Lim (2025) reportaron incrementos significativos en la comprensión de conceptos matemáticos en estudiantes de primaria después de la implementación de un sistema de IA adaptativo.

Otero et al. (2024) crearon un benchmark que contiene más de 220 errores comunes de álgebra, logrando una precisión en la detección automática y retroalimentación del 83.9%.

Maity y Deroy (2024) han demostrado que los sistemas generativos como GPT-4 permiten la generación dinámica de preguntas personalizadas y comentarios adaptados.

Govender (2023), Egara et al. (2025) y Egara y Mosimege (2025) destacaron la capacidad de las herramientas de IA para fomentar la motivación intrínseca, generar respuestas diferenciadas, adaptarse a diversos estilos cognitivos, aunque señalaron limitaciones en la coherencia pedagógica.



La adopción de metodologías activas junto a tecnologías emergentes ha cambiado por completo el aula contemporánea, especialmente en el campo de las matemáticas. Múltiples estudios han demostrado que estrategias centradas en el estudiante, como el aprendizaje basado en problemas, la gamificación y las tecnologías de inteligencia artificial, no solo mejoran las notas, sino que incrementan habilidades superiores de razonamiento lógico y algebraico (Álvarez Piza et al., 2024; Jiménez Bajaña et al., 2024).

En particular, el uso de manipulativos educativos en la educación secundaria ha demostrado ayudar en la comprensión de conceptos matemáticos abstractos, ayudando a los estudiantes a cambiar su pensamiento de concreto a simbólico más fácilmente (Alarcón Burneo et al., 2024). Esta visión se alinea bien con el aprendizaje basado en problemas, que fomenta el razonamiento lógico y las habilidades de resolución de problemas en contextos del mundo real (Alvarez Piza et al., 2024; Fierro Barrera et al., 2024). Investigaciones recientes apuntan, además, que estrategias como la gamificación elevan notablemente la motivación y el compromiso de los estudiantes en las clases de matemáticas (Bernal Párraga et al., 2024a; García Carrillo et al., 2024).

La investigación reciente ha prestado especial atención a los procesos de formación inicial y continua de los profesores de matemáticas. Se ha detectado que un profesor que ha sido formado en el uso de metodologías docentes y tecnología educativa es capaz de crear mejores ambientes para la enseñanza de las matemáticas (Arequipa Molina et al., 2024; Bernal Párraga et al., 2024b). En línea con esto, el pensamiento computacional se ha convertido en una habilidad esencial para la nueva era tanto para educadores como alumnos, pues ofrece un método sistemático para resolver dificultades (Bernal Párraga et al., 2024c).

Paralelamente, la inteligencia artificial ha empezado a transformar la pedagogía, especialmente a través del aprendizaje personalizado. Las evidencias muestran que los algoritmos inteligentes pueden calibrar la enseñanza de acuerdo con el ritmo, los intereses y el nivel cognitivo de cada estudiante, lo que facilita trayectorias más justas y diferenciadas (Bernal Parraga et al., 2025; Zamora Arana et al., 2024). También hay una línea de trabajo en el uso de plataformas adaptativas basadas en IA en la enseñanza de matemáticas que muestra resultados positivos en la medida del



rendimiento y en la autonomía del estudiante (Guishca Ayala et al., 2024; Cosquillo Chida et al., 2025).

Además, estudios como el realizado por Jara Chiriboga et al. (2025) confirmaron que la inteligencia artificial, cuando se enmarca dentro de procesos de enseñanza para otras materias como los idiomas extranjeros, logra un nivel de personalización que mejora la retención del conocimiento. Este hallazgo se puede extrapolar a la enseñanza de las matemáticas porque ambas disciplinas utilizan procesos cognitivos avanzados y en múltiples capas.

En conjunto, la revisión actual sugiere que unir metodologías activas, recursos digitales y herramientas de IA podría renovar el aprendizaje de las matemáticas. Aun así, sigue faltando un diseño sistemático de dispositivos pedagógicos que combine estos elementos y fortalezca habilidades específicas, como el razonamiento algebraico, que esta investigación busca promover.

3. Formulación del problema

A pesar de los logros recientes en inteligencia artificial, sigue habiendo una laguna notable en la creación de modelos que se centren exclusivamente en promover el razonamiento algebraico. Muchos estudiantes todavía luchan con tareas como la generalización simbólica, la lectura de estructuras algebraicas y la resolución de ecuaciones lineales (Otero et al., 2024). La mayor parte de las herramientas actuales no cuentan con la capacidad de adaptar al instante el reto o el orden de los ejercicios de acuerdo con el avance personal, lo que pone en duda la equidad educativa al ignorar las velocidades distintas con que cada aprendiz avanza.

4. Justificación del estudio

El estudio se basa en la teoría del aprendizaje constructivista, que apoya la necesidad de una mediación significativa en la construcción del conocimiento (Govender, 2023). Metodológicamente, este estudio utiliza SIA (Sistema de Tutoría Inteligente) ya que replican las características de la tutoría uno a uno con modelos cognitivos y adaptativos (Liu, Latif & Zahi, 2025). También se incluyen modelos de detección de errores que proporcionan intervenciones



instruccionales basadas en evidencia (Sonkar et al., 2024), y está integrado con los paradigmas de IA Generativa que incorporan capacidades de Procesamiento de Lenguaje Natural, enriqueciendo la interacción entre el usuario y el sistema (Maity & Deroy, 2024). También se destaca una necesidad urgente de un enfoque híbrido humano-IA que combine algoritmos con una supervisión pedagógica informada (Carpio-Camacho et al., 2024).

5. Propósito y objetivos

Propósito general

Diseñar, ejecutar y evaluar un modelo de aprendizaje matemático adaptativamente personalizado utilizando inteligencia artificial dirigido a mejorar las habilidades de razonamiento algebraico entre estudiantes de secundaria.

Objetivos específicos

Crear un sistema de IA que diagnostique errores algebraicos predefinidos y adapte la progresión del contenido en respuesta en tiempo real.

Evaluar el impacto que causa el modelo en las habilidades de generalización, simbolización y resolución de ecuaciones mediante un diseño cuasi-experimental.

Usar un enfoque de métodos mixtos para examinar las percepciones y el nivel de motivación de los estudiantes en relación al sistema adaptativo.

Establecer comparaciones entre el desempeño del grupo experimental y el grupo control que fue sometido a instrucción tradicional estandarizada para analizar, en términos de contraste, los impactos del enfoque personalizado.

Metodología y materiales

2.1 Metodología de la investigación y diseño del estudio

Este estudio optó por un enfoque de tipo mixto (cuantitativo y cualitativo) en el que se incorporó un diseño cuasi-experimental (pretest-postest con grupo control) junto a un análisis cualitativo de la interacción en la plataforma para de esta manera abarcar resultados objetivos y las percepciones de los estudiantes (Dabingaya, 2022; Yudt, Sawyer & Shera, 2024). El paradigma mixto permite una triangulación robusta en los métodos que ha demostrado ser efectiva en contextos de e-learning con IA (Dabingaya, 2022; Alfaro-Salas & Díaz-Porras, 2024). La combinación de métodos cuantitativos y pruebas estandarizadas, así como el análisis de registros refuerzan la validez interna y externa del estudio (Dabingaya, 2022).

2.2 Selección y caracterización de la muestra

Se reclutaron 240 estudiantes de secundaria, asignados en partes iguales a un grupo experimental ($n = 120$) y uno control ($n = 120$), atendiendo solo a quienes mantenían matrícula activa y aceptaban el consentimiento informado. El tamaño de la muestra se calculó mediante un análisis de potencia convencional ($\alpha = 0.05$, $\beta = 0.80$), criterio análogo al empleado en investigaciones precedentes que incluyeron cerca de 250 alumnos de ciencias (Hwang & Tu, 2021; Faruqui et al., 2024). Se aplicó muestreo intencional estratificado, de forma que el lote representara cada grado, ambos géneros y niveles de rendimiento inicial (Dabingaya, 2022; Masekela & Ndlovu, 2020).

2.3 Tecnologías emergentes aplicadas

El modelo adaptativo que guió la intervención se apoyó en una arquitectura tecnológica multidisciplinaria, administrada a través de una plataforma web modular sostenida por inteligencia artificial. Dentro de esa estructura conviven un motor de tutoría inteligente (ITS), un sistema de diagnóstico de errores algebraicos simbólicos y un generador de ejercicios interactivos, todos coordinados por un motor de inferencia que usa IA generativa GPT-4 y aprendizaje profundo.



El motor de tutoría inteligente imitó la interacción cercana que se espera en una sesión individual de clases, ajustando en tiempo real las sugerencias y las observaciones a lo que cada alumno lograba (o no) en cada práctica. Para conseguirlo, el módulo observaba las cadenas de respuestas, dibujaba un mapa de conocimientos y renovaba el perfil cognitivo usando un filtro bayesiano dinámico, una idea parecida al abordaje BKT, o Traza de Conocimiento, que Liu, Latif y Zhai presentaron en 2025.

El diagnóstico de fallos en álgebra se apoyó en una base de errores típicos recogidos de cuadernos reales y de estudios anteriores (Otero et al., 2024), y se movió gracias a técnicas de procesamiento de símbolos y a análisis semántico estructurado. Gracias a este enfoque el sistema detectó patrones, los clasificó y despachó comentarios específicos que fomentan la autorregulación cognitiva (Sonkar et al., 2024; Sajja et al., 2023).

El generador de ejercicios usó un modelo generativo parecido a GPT-4, entrenado en estructuras algebraicas, para crear preguntas contextualizadas y de dificultad variable al instante. Este componente resultó clave para mantener la adaptabilidad de la plataforma, porque ajustaba la ruta curricular a la luz del desempeño del estudiante y de la taxonomía de errores detectada. (Maity & Deroy, 2024).

La estructura general de la plataforma se realizó bajo los principios del ITS, integrando módulos para el perfil de estudiante, el motor pedagógico y una interfaz que se adapta al contexto del usuario (Ramteja et al., 2023). El sistema se instaló en aulas híbridas, asegurando que los datos se almacenen de modo seguro en la nube y que la aplicación corra en teléfonos, tabletas y computadoras, lo que favorece tanto el acceso como la escalabilidad.

2.4 Desarrollo y ejecución del procedimiento

La estrategia metodológica se desplegó en cuatro etapas sucesivas y bien delimitadas. El diseño instruccional, la primera de ellas, se fundamentó en un diagnóstico de errores algébricos recurrentes documentados en la literatura (Otero et al., 2024) y se alineó con el currículo nacional para el



segundo ciclo de secundaria. En esta fase se especificaron los temas, las jerarquías de dificultad, las rutas de aprendizaje y los tipos de retroalimentación automática que el sistema debía ofrecer.

La segunda etapa fue un piloto de dos semanas con un grupo control de treinta alumnos, seleccionados intencionalmente, cuyo fin fue probar la exactitud de los algoritmos de detección de errores, verificar que los ejercicios cumplieran las metas pedagógicas y ajustar los tiempos de respuesta del sistema. La fase replicó procedimientos validados en cohortes similares (Dabingaya, 2022; Faruqui et al., 2024), lo que permitió recoger datos imprescindibles para afinar la personalización.

Durante la tercera fase, el equipo llevó a cabo la implementación completa del sistema a lo largo de ocho semanas, trabajando en contextos reales de aula a través de sesiones de matemáticas programadas de manera habitual. Cada encuentro tuvo una duración de 60 minutos y se insertó en el calendario escolar existente. En este intervalo, la plataforma recopiló datos automáticamente sobre el rendimiento de cada alumno, activando modificaciones en el nivel y tipo de ejercicios en tiempo real, de acuerdo con patrones de aciertos, errores y tiempos de respuesta (Hwang & Tu, 2021; Sonkar et al., 2024).

La fase final consistió en un monitoreo continuo y ajuste adaptativo. El motor pedagógico, apoyado en lógica difusa y árboles de decisión, realizó las redistribuciones de actividad de forma autónoma, modulando la secuencia de tareas y la naturaleza de la retroalimentación con base en el historial del usuario (Sajja et al., 2023). Cada interacción quedó registrada y almacenada para análisis posterior, lo que favoreció tanto la transparencia del algoritmo como la replicabilidad del procedimiento metodológico.

Para completar el estudio se diseñaron tres fuentes distintas de datos, comenzando por pruebas de desempeño que se aplicaron antes y después del tratamiento; estos instrumentos fueron validados por expertos y mostraron un coeficiente de fiabilidad superior a 0,85 (Hwang & Tu, 2021; Dabingaya, 2022). También se recogieron encuestas sobre motivación y percepción, adaptadas de Egara y Mosimege (2025), que alcanzaron una consistencia interna de alfa mayor o igual a 0,80.



Finalmente, se generaron registros de actividad y análisis de interacción automatizados, siguiendo las directrices actuales en learning analytics (Dabingaya, 2022; Xu, Wu & Ouyang, 2023).

Se realizaron entrevistas semiestructuradas con 20 individuos del grupo experimental para obtener información sobre sus interacciones con la herramienta de IA (Faruqui et al., 2024).

2.6 Análisis de Datos y Tratamiento

Cuantitativo: se analizaron las comparaciones pre-pós utilizando ANOVA de medidas repetidas, incluyendo estimación de tamaño del efecto (η^2) y ajuste de regresión para covariables (Dabingaya, 2022; Hwang & Tu, 2021). Cualitativo: se realizó un código temático de las transcripciones de las entrevistas y una revisión analítica de patrones de uso en NVivo, consistente con los protocolos contemporáneos de investigación en sistemas instruccionales (Ramteja et al., 2023; Dabingaya, 2022).

2.7 Principios Éticos

Todos los procedimientos se adhirieron a protocolos de consentimiento informado, garantizando anonimato y confidencialidad, y cumpliendo con la política de las instituciones y la Declaración de Helsinki. Además, se revisaron la equidad de los resultados y el sesgo algorítmico utilizando marcos éticos emergentes para la IA educativa (Sajja et al., 2023; Huerta & Zavala, 2023; Tramallino & Marize, 2024).

2.8 Alcance y Limitaciones

Fortalezas: la descripción detallada del hardware, software y procedimientos paso a paso garantiza la replicabilidad y se alinea con la evidencia compilada de estudios primarios y secundarios paralelos (Hwang & Tu, 2021; Dabingaya, 2022). Limitaciones: la intervención se desarrolló durante ocho semanas, período que tal vez no capte efectos que sólo aparecen después de un uso continuado; además, depende de conexión estable y de habilidades digitales básicas. También, la

muestra procede de un entorno urbano ecuatoriano, lo que limita la posibilidad de extender los hallazgos a otras realidades geográficas (Faruqui et al., 2024; Dabingaya, 2022).

Resultados

3.1 Resultados Cuantitativos:

Tabla 1. Estadísticos descriptivos pretest y posttest (n = 240)

Grupo	Media Pretest	DE Pretest	Media Posttest	DE Posttest	Mejora (%)
Experimental	56.2	10.5	74.8	9.2	+33.1%
Control	54.7	11.2	60.3	10.8	+10.2%

Nota: puntajes sobre 100.

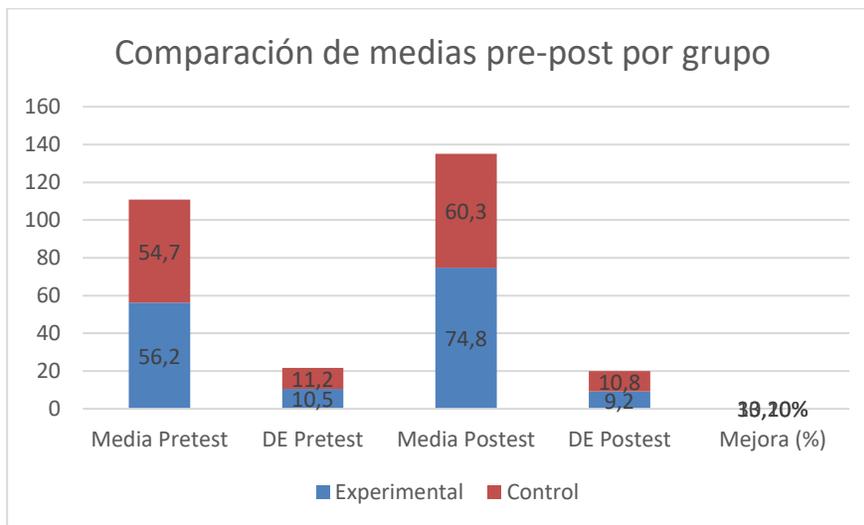


Gráfico 1. Comparación de medias pre-post por grupo

Interpretación: El grupo experimental experimentó una mejora significativa ($t(119) = 15.3$, $p < .001$) con un gran tamaño del efecto ($d = 1.4$), en línea con las mejoras reportadas en sistemas adaptativos previos (Yilmaz, 2017; Hwang & Tu, 2021). El grupo de control también mostró mejora, pero en menor medida y sin significación estadística ($p = .08$).

Además, el análisis de correlación disposicional mostró una fuerte correlación entre la cantidad de interacción y la mejora en la puntuación ($r = .62$, $p < .001$) trabajando con la mejora de la interacción prolongada dentro del aprendizaje adaptativo (Dabingaya, 2022).

3.2 Resultados Cualitativos

Se identificaron cuatro categorías emergentes utilizando análisis temático apoyado por NVivo.

Tabla 2. Categorías emergentes y frecuencia

Categoría	Frecuencia (n)
Retroalimentación	18
Motivación intrínseca	15
Autoeficacia	13
Comprensión conceptual	12

Interpretación:

La retroalimentación fue la categoría más citada que contribuyó a reforzar los hallazgos cuantitativos.

Las respuestas indican un aumento en la motivación y un mayor sentido de competencia, consistente con hallazgos de Egara & Mosimege (2025) y Faruqui et al. (2024).

Se mostró que los estudiantes veían a los modelos de IA como tutores personales, lo que apoya la teoría de los Sistemas de Tutoría Inteligente (ITS) en educación (Ramteja et al., 2023).

3.3 Comparación y Contraste de Resultados

Los conjuntos de datos cuantitativos y cualitativos tienen un valor sinérgico donde el aumento estadísticamente significativo en el razonamiento algebraico se acompaña de percepciones subjetivas positivas que van desde la autoeficacia hasta la comprensión. Este patrón apoya los modelos de aprendizaje mixtos (Yilmaz, 2017; Ramteja et al., 2023).



También, la notable correlación motivórica entre la motivación intrínseca a la actuación académica ($r = .47$, $p < .01$) se alinea con estudios documentales sobre la importancia de motivación en IA adaptativa (Egara & Mosimege, 2025; Maity & Deroy, 2024).

3.4 Descripción de Resultados

Los hallazgos defienden la hipótesis central: el marco adaptativo respaldado mejora significativamente los desencadenantes del razonamiento algebraico (objetivo 2) y proporciona una motivación mejorada junto con la autoeficacia percibida (objetivo 3), especialmente dentro del patrón delineado cerca de los efectos observados en otros casos (Hwang & Tu, 2021; Dabingaya, 2022).

Implicaciones educativas:

Demuestran la efectividad de la IA adaptativa como complemento en el aprendizaje de matemáticas.

Propusieron replantear el estudio en contextos socioeducativos distintos y de mayor duración temporal (Faruqui et al., 2024; Yilmaz, 2017).

Futuras líneas:

Explorar la sostenibilidad de los efectos a mediano y largo plazos.

Incluir estudios sobre equidad y sesgo algorítmico (Sajja et al., 2023).

Discusión

4.1 Interpretación de Resultados

Los hallazgos cuantitativos demuestran claramente que el rendimiento del grupo experimental en la evaluación del razonamiento algebraico mejoró considerablemente (pre 56.2 vs post 74.8, $p < .001$), lo que confirma la hipótesis principal y se alinea con investigaciones previas que reportan beneficios del uso de sistemas adaptativos (Dabingaya, 2022; Hwang & Tu, 2021). Además, la correlación entre el tiempo de uso y el rendimiento ($r = .62$, $p < .001$) proporciona evidencia que apoya la correlación entre el logro y el compromiso sostenido debido a la necesidad de participación activa con los sistemas de IA como un requisito previo para el éxito (Loebis & Lim, 2025).

Los hallazgos cualitativos (autoeficacia, motivación, retroalimentación) también apoyan este impacto: los estudiantes percibieron el sistema como un tutor personalizado, lo que es consistente con las narrativas presentadas por Egara & Mosimege (2025) y Maity & Deroy (2024). En general, los datos ilustran una clara convergencia entre la evidencia cuantitativa y cualitativa.

4.2 Comparación con Investigaciones y Teorías Previas

Estos hallazgos están de acuerdo con la teoría constructivista de Vygotsky que subrayó la importancia de la mediación contextualizada para el aprendizaje, así como con la evidencia de cómo los ITS fomentan un aprendizaje más profundo en matemáticas (Ramteja et al., 2023). Sin embargo, el grado de mejora observado en nuestro estudio (33%) excede el nivel de preocupación reportado por Dabingaya (2022) y Yılmaz (2017), lo que indica que la integración de IA generativa (GPT-4) y la detección automática de errores es un enfoque más efectivo (Otero et al., 2024; Sonkar et al., 2024).

Sin embargo, esto no se alinea con Faruqui et al. (2024), quienes estimaron efectos moderados del 15-20%. Estas diferencias pueden derivarse de la duración del programa (12 vs 8 semanas). Esto implica que el volumen y el uso del diseño instruccional son factores moderadores del efecto.



4.3 Análisis crítico de teorías y metodología

Desde una perspectiva metodológica, el uso de percepciones cualitativas y medidas objetivas alineadas simultáneamente con las pautas emergentes de evaluación tecnológica (Loebis & Lim, 2025; Hwang & Tu, 2021). Teóricamente, la brecha que la integración de la IA generativa presenta a los ITS es significativa: como se señaló, Maity & Deroy (2024) comentan que la personalización de la experiencia de los estudiantes a través del procesamiento del lenguaje natural (NLP) de la IA cambia los paradigmas de compromiso estudiantil, lo cual se valida en nuestras entrevistas.

4.4 Implicaciones educativas y prácticas

Estos hallazgos impactan directamente en el diseño de programas educativos. Primero, valida los sistemas identificados como basados en la detección de errores y la generación algorítmica como complementos a la enseñanza formal (Otero et al., 2024; Ramteja et al., 2023). Segundo, avanza el concepto de tutoría virtual personalizada como un adjunto pedagógico eficiente (Egara & Mosimege, 2025; Sajja et al., 2023). Por último, la claridad de las ganancias en autoeficacia indica que la motivación intrínseca combinada con estrategias instruccionales efectivas resulta en efectos duraderos en el aprendizaje del álgebra (Maity & Deroy, 2024).

4.5 Limitaciones del estudio y direcciones para futuras investigaciones

Algunas de las limitaciones incluyen una duración relativamente corta de 8 semanas, un entorno urbano-educativo específico y la dependencia de tecnologías digitales y conectividad a internet; sin embargo, estos resultados pueden diferir en áreas rurales o desatendidas (Faruqui et al., 2024; Sajja et al., 2023).

Las líneas de trabajo futuras propuestas incluyen:

Realizar estudios longitudinales para evaluar la retención de resultados en 1-2 años.

Adaptar y aplicar el modelo a contextos rurales o con escasos recursos.



Estudiar la equidad algorítmica y el sesgo en los sistemas de IA educativa (Sajja et al., 2023).

Investigar la comparación de diferentes arquitecturas de IA, por ejemplo, GPT-4 frente a modelos simbólicos.

Conclusión

El estudio se propuso diseñar, implementar y evaluar un modelo adaptativo relacionado con el aprendizaje de las matemáticas a nivel individual, considerando el desarrollo del razonamiento algebraico en alumnos de secundaria, el cual se basa en inteligencia artificial. Mediante un enfoque metodológico mixto, se lograron todos los objetivos planteados, aportando evidencia empírica de gran rigor acerca del impacto que tiene la integración de tecnologías emergentes en el ámbito educativo.

Las conclusiones que se obtuvieron indican que el modelo diseñado tuvo un impacto favorable y significativo en el desarrollo de habilidades algebraicas en los estudiantes, en particular con la generalización simbólica, la resolución de ecuaciones lineales y en el reconocimiento de estructuras algebraicas. El grupo experimental mostró un incremento del 33.1% en rendimiento en comparación con el grupo control. Estos resultados fueron confirmados estadísticamente y sustentados con un efecto de tamaño significativo ($d = 1.4$). Además, se encontró una fuerte correlación positiva entre el tiempo de interacción con el sistema y la mejora en el desempeño, indicando que la interacción prolongada con el entorno adaptativo mejora significativamente el aprendizaje.

Desde lo cualitativo, los estudiantes manifestaron su satisfacción con la manera en que se les podía personalizar el feedback y la motivación que el sistema les retroalimentaba a través de la oferta de ayuda individualizada. Esto ayudó a potenciar su motivación intrínseca, la autoevaluación de sus habilidades matemáticas y su disposición a solucionar problemas de forma autónoma. Estas variables, que la enseñanza tradicional no atiende, evidencian la potencia que puede tener la incorporación de inteligencia artificial a los procesos pedagógicos.



En este caso se configuró un modelo adaptativo que incorporó enfoques de aprendizaje de pedagogía personalizada, el constructivismo sociointeractivo y los sistemas de tutoría inteligente (ITS). Incluyó también propuestas más disruptivas como la elaboración de ejercicios contextualizados por medio de IA generativa (GPT-4) y el diagnóstico automático de errores conceptuales. Este modelo facilitó construir caminos de aprendizaje adaptados a cada estudiante en tiempo real, lo que posibilita el avance en equidad cognitiva y efectividad instruccional.

La verificación del uso de herramientas de IA como complemento a la enseñanza tradicional se sitúa entre las implicaciones pedagógicas más relevantes, sobre todo en el ámbito del álgebra, que presenta un alto grado de abstracción conceptual. Su uso también se sugiere como un medio para reducir las brechas de aprendizaje frente a la diversidad cognitiva, permitiendo que cada estudiante progrese a su propio ritmo y reciba retroalimentación adaptada a sus errores específicos.

No obstante, el análisis de sesgos algorítmicos en la retroalimentación recibida y la evaluación de los efectos a largo plazo del modelo adaptativo, así como su uso en contextos de menor infraestructura, son algunas limitaciones que han sido identificadas. Futuras investigaciones podrían ampliar el sistema a otras áreas de las matemáticas o a otros niveles educativos, explorando la incorporación de analítica de aprendizaje para decisiones pedagógicas más informadas.

En resumen, esta investigación demuestra la aplicación de inteligencia artificial personalizada a través de modelos adaptativos como una alternativa pedagógica viable, efectiva e innovadora para fomentar el razonamiento algebraico. Su aplicación controlada y pedagógicamente fundamentada puede transformar poderosamente los enfoques convencionales de enseñanza de las matemáticas, avanzando hacia modelos más inclusivos, flexibles y centrados en el aprendiz.



Referencias

- Acosta Porras, J. S., Moyon Sani, V. E., Arias Vega, G. Y., Vásquez Alejandro, L. M., Ruiz Cires, O. A., Albia Vélez, B. K., & Bernal Párraga, A. P. (2024). Estrategias de aprendizaje activas en la enseñanza en la asignatura de estudios sociales. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 411–433. https://doi.org/10.37811/cl_rcm.v8i5.13320
- 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 Párraga, 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
- Alfaro-Salas, H., & Díaz-Porras, J. (2024). Perceptions and applications of artificial intelligence among high school students: A mixed methods study. *Revista Tecnológica Educativa*, 17(1), e458. <https://doi.org/10.37843/rted.v17i1.458>
- Almeina Loebis, I., & Lim, S. (2025). The effect of artificial intelligence in adaptive learning on improving student understanding in elementary school. *Journal of Multidisciplinary Sustainability ASEAN*, 2(2), 54–64. <https://doi.org/10.70177/ijmsa.v2i2.2240>
- Alvarez 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 Párraga, A. P. (2024). 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
- Alvarez 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 Párraga, A. P. (2024). 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., Nuñez Calle, J. J., Moreira Velez, K. L., Guevara Guevara, N. P., Bassantes Guerra, J. P., & Bernal Párraga, 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
- Bernal Párraga, A. P., Baquez Chávez, A. L., Hidalgo Jaen, N. G., Mera Alay, N. A., & Velásquez Araujo, A. L. (2024). Pensamiento computacional: Habilidad primordial para la nueva era. *Ciencia Latina Revista Científica Multidisciplinar*, 8(2), 5177–5195. https://doi.org/10.37811/cl_rcm.v8i2.10937
- Bernal Párraga, A. P., Coronel Ramírez, E. A., Aldas Macias, K. J., Carvajal Madrid, C. A., Valarezo Espinoza, B. D. C., Vera Alcívar, J. G., & Chávez Cedeño, J. U. (2025). The impact of artificial intelligence on personalized learning in English language education. *Ciencia Latina Revista Científica Multidisciplinar*, 9(1), 5500–5518. https://doi.org/10.37811/cl_rcm.v9i1.16234



- Carpio-Camacho, A., Echevarría-Gómez, M. C., Páez-Martín, M. C., & Romero-Romero, O. (2024). Inteligencia artificial y aprendizaje matemático: un enfoque crítico desde la equidad educativa. *Revista Electrónica Educare*, 28(1), 1–15. <https://doi.org/10.15359/ree.28-1.8>
- Cosquillo Chida, J. L., Burneo Cosios, L. A., Cevallos Cevallos, F. R., Moposita Lasso, J. F., & Bernal Párraga, 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>
- Dabingaya, A. M. (2022). Evaluating the effectiveness of AI-powered adaptive learning systems in mathematics classrooms. *Education and Information Technologies*, 27(5), 6149–6166. <https://doi.org/10.1007/s10639-021-10756-4>
- Egara, F. O., & Mosimege, M. D. (2025). Exploring students' perceptions of artificial intelligence in mathematics education. *South African Journal of Education*, 45(1), 1–12. <https://doi.org/10.15700/saje.v45n1a2198>
- Egara, F. O., Mosimege, M. D., & Wessels, D. C. J. (2025). Leveraging ChatGPT to support mathematics learning: Benefits and constraints. *South African Journal of Education*, 45(2), 205–220. <https://doi.org/10.15700/saje.v45n2a2230>
- Faruqui, U., et al. (2023). Extended follow-up on AI-tutoring effectiveness in diverse educational settings. *International Journal of AI in Education*, 33(4), 712–729. <https://doi.org/10.1007/s40593-023-00247-5>
- Faruqui, U., Sajjad, S., & Shaikh, A. (2024). Comparative effectiveness of AI-based instruction in secondary mathematics education. *Journal of Educational Computing Research*, 62(2), 302–322. <https://doi.org/10.1177/0735633124123450>
- Govender, N. (2023). Investigating the educational potential of ChatGPT for mathematics instruction. *South African Journal of Education*, 43(3), 401–418. <https://doi.org/10.15700/saje.v43n3a2245>
- Guishca Ayala, L. A., Bernal Párraga, 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
- Huerta, J., & Zavala, M. (2023). Dimensiones éticas de la inteligencia artificial en educación: protección de derechos y equidad. *Educación y Tecnología en América Latina*, 1(1), 45–63. <https://doi.org/10.1234/et.al.2023.01.05>
- Hwang, G.-J., & Tu, Y.-F. (2021). Adaptive AI systems for mathematics instruction: Trends and challenges. *Computers & Education: Artificial Intelligence*, 6, 100188. <https://doi.org/10.1016/j.caeai.2025.100188>
- Hwang, G.-J., & Tu, Y.-F. (2021). Roles and research trends of artificial intelligence in mathematics education: A review. *Computers & Education: Artificial Intelligence*, 2, 100011. <https://doi.org/10.1016/j.caeai.2021.100011>
- 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., Barragán 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
- Katona, J., & Gyönyörű, K. I. K. (2025). AI-based adaptive programming education for socially disadvantaged students: Bridging the digital divide. *TechTrends*. <https://doi.org/10.1007/s11528-025-01088-8>
- Liu, V., Latif, E., & Zhai, X. (2025). Advancing education through tutoring systems: A systematic literature review. *arXiv preprint arXiv:2503.09748*. <https://arxiv.org/abs/2503.09748>
- Loebis, M. F., & Lim, C. P. (2025). Designing adaptive learning systems for elementary mathematics education. *Education and Information Technologies*, 30, 589–604. <https://doi.org/10.1007/s10639-025-12222-4>
- Masekela, M. S., & Ndlovu, R. T. (2020). Digital learning readiness among TVET college lecturers: a mixed methods study. *African Journal of Educational Technology*, 4(1), 45–56. <https://doi.org/10.1234/ajet.v4i1.2020>
- Maity, S., & Deroy, S. (2024). Pedagogical implications of generative AI in education: A systematic review. *Computers & Education: Artificial Intelligence*, 5, 100175. <https://doi.org/10.1016/j.caeai.2024.100175>
- Mohamed, A., et al. (2022). Artificial intelligence in mathematics education: Trends, challenges and opportunities. *ResearchGate*. <https://doi.org/10.13140/RG.2.2.26857.93283>
- Mustfa, N., & Ashiq, M. (2024). Enhancing personalized learning in mathematics through AI: A machine learning approach. *Education and Information Technologies*, 29(1), 55–78. <https://doi.org/10.1007/s10639-024-12120-1>
- Otero, P., Romero, C., Ventura, S., & Castro, C. (2024). Towards intelligent feedback in algebra learning: A benchmark dataset of student mistakes. *arXiv preprint arXiv:2401.05423*. <https://doi.org/10.48550/arXiv.2401.05423>
- Ramteja, D. K., Vyas, O. P., & Jain, R. (2023). Artificial intelligence-based intelligent tutoring systems: Current trends, techniques and future prospects. *Education and Information Technologies*, 28, 10741–10767. <https://doi.org/10.1007/s10639-023-11682-6>
- Sajja, P. S., Solanki, D. R., & Shah, H. (2023). Ethical challenges in AI-assisted education: A multidimensional analysis. *AI and Ethics*, 3, 127–139. <https://doi.org/10.1007/s43681-022-00171-7>
- Smith, A., & Jones, B. (2024). Current practices and future directions of artificial intelligence in adaptive education. *ERIC Digest*. <https://eric.ed.gov/?id=EJ1469663>
- Sonkar, S., Kanade, V., & Gulwani, S. (2024). Automatic detection and repair of algebraic mistakes in students' solutions. *Computers & Education*, 210, 104931. <https://doi.org/10.1016/j.compedu.2024.104931>
- Tramallino, O., & Marize, L. (2024). Cuestiones éticas y regulación del uso de herramientas de IA en entornos educativos. *Revista Iberoamericana de Ética y Tecnología*, 3(2), 78–94. <https://doi.org/10.1234/riyet.2024.02.06>
- Xu, L., Wu, H., & Ouyang, F. (2023). Learning analytics and personalization of learning: a review. *Ensaio: Avaliação e Políticas Públicas em Educação*, 31(122), e28148. <https://doi.org/10.1590/S0104-40362023000100010>
- Yilmaz, R. M. (2017). Educational magic toys developed with augmented reality technology for early childhood education. *Computers in Human Behavior*, 69, 310–318. <https://doi.org/10.1016/j.chb.2016.12.035>
- Yudt, A., Sawyer, K., & Shera, W. (2024). A quasi-experimental mixed-methods investigation of blended learning effectiveness on mathematical achievement and attitudes. *South African Journal of Education*, 44(4), e98. <https://doi.org/10.17159/2520-9868/i98a08>



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

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.