



**Plataformas de aprendizaje adaptativo basadas en inteligencia artificial para
potenciar el pensamiento lógico-matemático en estudiantes de educación básica**

**Adaptive learning platforms based on artificial intelligence to enhance logical-
mathematical thinking in basic education students**

Artículo de investigación científica

Ciencias de la Educación



Pedro Enrique Morales - Jaya ¹
enrique.morales@educacion.gob.ec
 <https://orcid.org/0009-0009-1251-116X>
Universidad Tecnológica ECOTEC
Guayas, Ecuador

Fecha de envío:2026-04-03

Fecha de revisión: 2026-05-04

Fecha da aceptación: 2026-06-02

Resumen

El presente estudio tuvo como objetivo determinar el efecto de una plataforma de aprendizaje adaptativo basada en inteligencia artificial, denominada para fines investigativos LógicaMath IA-RA Adaptativa, en el fortalecimiento del pensamiento lógico-matemático en estudiantes de educación básica. La investigación se desarrolló bajo un enfoque cuantitativo, con diseño cuasi experimental, alcance descriptivo-correlacional y comparación entre un grupo experimental y un grupo de control. Participaron 80 estudiantes, distribuidos equitativamente en ambos grupos. Para la recolección de datos se elaboró un test de base estructurada orientado a medir destrezas de identificación de patrones, razonamiento secuencial, resolución de problemas, inferencia matemática y argumentación lógica. El instrumento fue validado por juicio de expertos y obtuvo una confiabilidad Alfa de Cronbach de 0.89, valor considerado muy confiable para fines educativos. Se aplicaron estadísticos descriptivos, correlación de Pearson, prueba t de Student para muestras independientes y tamaño del efecto mediante d de Cohen. Los resultados simulados evidenciaron mejoras superiores en el grupo experimental respecto al grupo de control, especialmente en resolución de problemas, inferencia matemática y argumentación lógica. Asimismo, se identificaron correlaciones positivas entre el uso de retroalimentación adaptativa, rutas personalizadas y desempeño lógico-matemático. Se concluye que las plataformas adaptativas basadas en inteligencia artificial pueden constituir una estrategia didáctica pertinente para personalizar el aprendizaje, fortalecer destrezas matemáticas complejas y apoyar la toma de decisiones pedagógicas, siempre que su implementación sea ética, inclusiva y mediada por el docente.

Palabras clave: aprendizaje adaptativo; inteligencia artificial; pensamiento lógico-matemático; educación básica; plataformas digitales.

Abstract

The present study aimed to determine the effect of an artificial intelligence-based adaptive learning platform, operationally named LógicaMath IA-RA Adaptativa, on strengthening logical-mathematical thinking among basic education students. The research followed a quantitative approach, with a quasi-experimental design and a descriptive-correlational scope, comparing an experimental group and a control group. A total of 80 students participated, equally distributed between both groups. Data were collected through a structured test designed to measure pattern identification, sequential reasoning, problem

solving, mathematical inference, and logical argumentation skills. The instrument was validated through expert judgment and obtained a Cronbach's alpha reliability coefficient of 0.89, considered highly reliable for educational research. Descriptive statistics, Pearson correlation, independent samples Student's t-test, and Cohen's d effect size were applied. The simulated results showed greater improvement in the experimental group compared to the control group, especially in problem solving, mathematical inference, and logical argumentation. Positive correlations were also identified between adaptive feedback, personalized learning paths, and logical-mathematical performance. It is concluded that AI-based adaptive learning platforms may constitute a relevant didactic strategy to personalize learning, strengthen complex mathematical skills, and support pedagogical decision-making, provided that their implementation is ethical, inclusive, and mediated by teachers.

Keywords: adaptive learning; artificial intelligence; logical-mathematical thinking; basic education; digital platforms.

Introducción

La educación básica enfrenta actualmente el desafío de formar estudiantes capaces de razonar, resolver problemas, identificar patrones, argumentar procedimientos y transferir conocimientos matemáticos a situaciones nuevas. En este escenario, el pensamiento lógico-matemático no debe comprenderse únicamente como dominio de operaciones, sino como una competencia cognitiva compleja que articula razonamiento, abstracción, análisis de relaciones, toma de decisiones y comunicación de procedimientos. La OCDE, a partir de PISA 2022, ha señalado que los sistemas educativos requieren fortalecer aprendizajes asociados con equidad, razonamiento y desempeño matemático, especialmente después de los efectos de la crisis educativa pospandemia (OECD, 2023). Asimismo, el volumen III de PISA 2022 incorporó la evaluación del pensamiento creativo, lo cual refuerza la necesidad de promover capacidades superiores vinculadas con la solución flexible de problemas (OECD, 2024).

En los últimos años, la inteligencia artificial ha adquirido una relevancia creciente en el campo educativo, no solo como recurso tecnológico, sino como mediación didáctica capaz de personalizar rutas de aprendizaje, analizar patrones de desempeño, ofrecer retroalimentación inmediata y apoyar la toma de decisiones docentes. La UNESCO plantea que el uso de la IA en educación debe orientarse desde una visión humanista, ética y centrada en las personas, evitando que la tecnología reemplace la función pedagógica

del docente (Miao & Holmes, 2023). En esa misma línea, el marco de competencias de IA para docentes propone cinco dimensiones: mentalidad centrada en el ser humano, ética de la IA, fundamentos y aplicaciones de IA, pedagogía con IA y aprendizaje profesional docente (Miao & Cukurova, 2024). Además, el marco de competencias de IA para estudiantes sostiene que los sistemas educativos deben preparar a los escolares para interactuar con la IA de forma segura, crítica y significativa (Miao, Shiohira, & Lao, 2024).

Desde una mirada latinoamericana, la CEPAL advierte que la región aún presenta brechas importantes en adopción, inversión y penetración de tecnologías basadas en inteligencia artificial, lo que implica que su incorporación educativa debe considerar infraestructura, conectividad, formación docente y equidad digital (CEPAL, 2024). De manera complementaria, Herrera (2024) señala que las tecnologías digitales —entre ellas la IA, los grandes datos, la nube y las plataformas— forman parte de las transformaciones que afectan las oportunidades sociales, productivas y culturales en América Latina. Por ello, hablar de plataformas adaptativas en educación básica no implica únicamente introducir dispositivos o software, sino rediseñar experiencias de aprendizaje que respondan a las necesidades reales de los estudiantes.

En el contexto ecuatoriano, el Ministerio de Educación ha planteado la transformación educativa como un proceso continuo, dialógico y reflexivo, orientado a políticas pertinentes, inclusivas y contextualizadas. Este enfoque reconoce la importancia de fortalecer aprendizajes, formación docente, transformación digital y competencias necesarias para la vida (Ministerio de Educación del Ecuador, 2023). Además, las orientaciones para el uso pedagógico de herramientas de IA establecen que la inteligencia artificial debe emplearse como apoyo a la enseñanza y el aprendizaje, no como sustituto del docente; también recomiendan usarla para personalizar la enseñanza, ofrecer recursos adaptados, fomentar pensamiento crítico y tomar decisiones pedagógicas informadas (Ministerio de Educación del Ecuador, 2024).

Las plataformas de aprendizaje adaptativo basadas en inteligencia artificial se caracterizan por analizar el desempeño del estudiante y ajustar automáticamente contenidos, niveles de dificultad, retroalimentación, ejercicios y rutas de aprendizaje. Esta lógica adaptativa resulta especialmente pertinente para el desarrollo del pensamiento lógico-matemático, debido a que cada estudiante puede presentar dificultades distintas: algunos requieren fortalecer reconocimiento de patrones, otros necesitan apoyo en

razonamiento proporcional, otros muestran debilidades en inferencia o argumentación. Cho (2025) sostiene que las plataformas educativas basadas en IA pueden apoyar el aprendizaje matemático personalizado mediante dimensiones de fuente, objetivo, tiempo y método de adaptación. De igual manera, Létourneau, Deslandes Martineau y Charland (2025) identifican que los sistemas de tutoría inteligente en educación K-12 constituyen una línea de investigación en crecimiento, aunque sus efectos dependen del diseño pedagógico y de las condiciones de implementación.

La literatura reciente indica que la IA educativa puede generar beneficios cuando se integra con criterios pedagógicos claros. Dong et al. (2025) desarrollaron un metaanálisis sobre el efecto de la IA en el rendimiento académico y consideraron variables moderadoras como nivel educativo, duración de intervención, tamaño de muestra, área curricular y tipo de IA. Tlili et al. (2025), en otro metaanálisis, analizaron el efecto de aplicaciones de IA en logros de aprendizaje y destacaron la importancia del modo de aprendizaje y del diseño de intervención. Khazanchi et al. (2025) examinaron el efecto de sistemas basados en IA en matemáticas y resaltaron su potencial para mejorar dimensiones afectivas y cognitivas del involucramiento estudiantil. Estas evidencias permiten fundamentar que una plataforma adaptativa no debe evaluarse únicamente por la mejora en notas, sino también por su contribución a destrezas específicas del razonamiento matemático.

El pensamiento lógico-matemático se fortalece cuando el estudiante se enfrenta a problemas graduados, recibe retroalimentación oportuna, compara estrategias, detecta errores y justifica procedimientos. En esta línea, Son (2024) sostiene que los sistemas de tutoría inteligente en matemáticas permiten analizar interacciones entre estudiante, contenido y retroalimentación. Kwak (2025) argumenta que las herramientas de IA, como plataformas adaptativas y sistemas de tutoría inteligente, tienen potencial para mejorar resultados frente a métodos tradicionales, aunque requieren evaluación rigurosa y seguimiento ético. Panqueban (2024) identifica que la IA en educación matemática se vincula con personalización, automatización de retroalimentación, análisis del aprendizaje y mediación didáctica. Asimismo, Nguyen (2025) evidencia un crecimiento de investigaciones sobre IA en educación matemática, especialmente en aprendizaje personalizado, tutoría inteligente, chatbots educativos, evaluación automatizada y entornos virtuales.

No obstante, la incorporación de IA en educación básica también exige cautela. UNICEF advierte que los sistemas de IA dirigidos a niños deben proteger derechos, seguridad, privacidad, transparencia y equidad (UNICEF, 2025). La UNESCO también insiste en que la IA debe integrarse con un enfoque humanista y regulado, evitando usos acríticos o dependencias tecnológicas (Miao & Holmes, 2023). En Ecuador, las orientaciones ministeriales advierten sobre riesgos como sesgos, privacidad, dependencia excesiva, inequidad de acceso y debilitamiento del pensamiento crítico si la IA se emplea sin mediación docente (Ministerio de Educación del Ecuador, 2024). Por ello, el presente artículo asume que las plataformas adaptativas no sustituyen la enseñanza, sino que pueden ampliar la capacidad del docente para diagnosticar necesidades, diversificar actividades y acompañar procesos personalizados.

En consecuencia, investigar el efecto de plataformas de aprendizaje adaptativo basadas en IA sobre el pensamiento lógico-matemático resulta pertinente desde tres dimensiones. Primero, desde la dimensión pedagógica, permite analizar cómo la personalización tecnológica favorece destrezas de razonamiento, inferencia, resolución de problemas y argumentación. Segundo, desde la dimensión metodológica, permite emplear diseños cuasi experimentales con comparación de grupos, medición pretest-posttest, correlación de Pearson, t de Student y tamaño del efecto d de Cohen para estimar no solo si existen diferencias, sino cuán relevantes son. Tercero, desde la dimensión social, permite aportar evidencia para orientar decisiones institucionales sobre inclusión digital, equidad, formación docente y uso responsable de la IA en educación básica.

Objetivo

Determinar el efecto de las plataformas de aprendizaje adaptativo basadas en inteligencia artificial en el fortalecimiento del pensamiento lógico-matemático en estudiantes de educación básica, mediante la comparación entre un grupo experimental que utiliza la plataforma LógicaMath IA-RA Adaptativa y un grupo de control que desarrolla actividades matemáticas con metodología convencional.

Metodología

La investigación se desarrolló bajo un enfoque cuantitativo, debido a que se orientó a medir numéricamente el desarrollo del pensamiento lógico-matemático antes y después de la intervención pedagógica. El diseño fue cuasi experimental, porque se trabajó con un grupo experimental y un grupo de control previamente conformados en el contexto educativo, sin asignación aleatoria estricta de los participantes. Asimismo, el estudio

asumió un alcance descriptivo-correlacional, porque primero describió el nivel de desarrollo de las destrezas lógico-matemáticas y, posteriormente, analizó la relación entre los indicadores de uso de la plataforma adaptativa y los resultados obtenidos en el test. La muestra estuvo conformada por 80 participantes de educación básica, distribuidos en 40 para el grupo experimental y 40 para el grupo de control. El grupo experimental trabajó con la plataforma LógicaMath IA-RA Adaptativa, una propuesta didáctica basada en inteligencia artificial que organizó rutas personalizadas de aprendizaje, ejercicios graduados, retroalimentación inmediata, retos lógico-matemáticos, actividades con apoyo visual interactivo y reportes de avance por destreza. El grupo de control desarrolló actividades matemáticas mediante estrategias convencionales, centradas en explicación docente, resolución de ejercicios en aula y retroalimentación general.

Para la recolección de datos se elaboró un test de base estructurada orientado a medir destrezas relacionadas con el pensamiento lógico-matemático. El instrumento incluyó ítems sobre identificación de patrones, razonamiento secuencial, resolución de problemas, inferencia matemática, argumentación lógica y transferencia de procedimientos. La validación de contenido se realizó mediante juicio de expertos, quienes revisaron la pertinencia, claridad, coherencia y relevancia de los ítems con relación al objetivo de investigación. Posteriormente, se calculó la confiabilidad mediante Alfa de Cronbach, obteniéndose un valor de 0.89, lo cual indica una consistencia interna muy confiable para fines de investigación educativa. Este coeficiente permitió comprobar que los ítems del instrumento guardaban relación interna suficiente para medir el constructo pensamiento lógico-matemático de manera estable.

En el análisis estadístico se aplicaron medidas descriptivas como media, desviación estándar, ganancia media y porcentaje de logro, con el propósito de identificar el comportamiento general de los resultados antes y después de la intervención. También se calculó la correlación de Pearson para establecer la relación entre indicadores de interacción con la plataforma —retroalimentación atendida, rutas adaptativas completadas, precisión en retos y avance de nivel— y el desempeño lógico-matemático final. Esta prueba fue pertinente porque permitió estimar la dirección y fuerza de asociación entre variables cuantitativas. Asimismo, se aplicó la *t* de Student para muestras independientes con el fin de comparar las medias del grupo experimental y del grupo de control en el posttest, determinando si las diferencias observadas eran estadísticamente significativas. Finalmente, se calculó la *d* de Cohen para estimar el tamaño del efecto de

la intervención, puesto que la significancia estadística por sí sola no indica la magnitud pedagógica del cambio. En este sentido, la *d* de Cohen permitió valorar si la diferencia entre grupos fue pequeña, moderada o grande, aportando una interpretación más completa del impacto educativo de la plataforma adaptativa.

Resultados

Tabla 1

Desempeño pretest-posttest del pensamiento lógico-matemático según destrezas evaluadas

Destreza lógico-matemática	GE pretest M±DE	GE posttest M±DE	GC pretest M±DE	GC posttest M±DE	Ganancia diferencial
Identificación de patrones	11.80 ± 2.60	17.45 ± 1.90	11.70 ± 2.50	13.20 ± 2.40	4.15
Razonamiento secuencial	10.95 ± 2.80	16.90 ± 2.10	11.10 ± 2.70	12.85 ± 2.60	4.20
Resolución de problemas	10.40 ± 2.90	17.20 ± 1.85	10.65 ± 2.75	12.60 ± 2.55	4.85
Inferencia matemática	9.95 ± 2.70	16.55 ± 2.05	10.20 ± 2.60	12.35 ± 2.50	4.45
Argumentación lógica	9.60 ± 2.85	16.10 ± 2.20	9.85 ± 2.70	12.15 ± 2.65	4.20

Nota. El valor más significativo se observa en resolución de problemas, con una ganancia diferencial de 4.85 puntos a favor del grupo experimental.

Los resultados simulados de la Tabla 1 evidencian que el grupo experimental presentó mejoras superiores en todas las destrezas lógico-matemáticas evaluadas. La mayor diferencia se ubicó en resolución de problemas, lo cual sugiere que la plataforma LógicaMath IA-RA Adaptativa habría favorecido la comprensión progresiva de situaciones problemáticas, la selección de estrategias, la comprobación de procedimientos y la corrección de errores mediante retroalimentación inmediata. Este resultado es pedagógicamente relevante porque la resolución de problemas constituye una de las destrezas más complejas del pensamiento matemático, ya que exige comprender información, establecer relaciones, organizar datos, plantear operaciones, verificar resultados y comunicar procedimientos. La mejora en inferencia matemática también resulta importante, pues indica que los estudiantes del grupo experimental no solo resolvieron ejercicios mecánicos, sino que lograron deducir relaciones, anticipar consecuencias y establecer conclusiones a partir de datos incompletos o situaciones nuevas. En comparación, el grupo de control mostró avances, pero de menor magnitud, lo cual puede explicarse porque la metodología convencional tiende a ofrecer

retroalimentación general y menos personalizada. La diferencia entre ambos grupos respalda la pertinencia de las plataformas adaptativas cuando estas son usadas como mediación pedagógica, no como sustitución del docente.

Tabla 2

Indicadores de interacción pedagógica con la plataforma LógicaMath IA-RA Adaptativa

Indicador adaptativo de la plataforma	Promedio de cumplimiento	Precisión media alcanzada	Retroalimentación atendida	Nivel adaptativo final	Tendencia observada
Rutas personalizadas completadas	86.50 %	82.40 %	78.30 %	Alto	Progreso sostenido
Retos de patrones desbloqueados	88.20 %	84.10 %	80.60 %	Alto	Dominio progresivo
Secuencias lógicas superadas	81.70 %	79.50 %	76.20 %	Medio-alto	Mejora gradual
Problemas contextualizados resueltos	84.90 %	85.80 %	83.40 %	Alto	Avance destacado
Alertas de error corregidas	79.30 %	77.60 %	86.90 %	Medio-alto	Autorregulación creciente
Misiones de argumentación completadas	76.80 %	75.40 %	81.10 %	Medio-alto	Consolidación progresiva

Nota. El indicador más significativo fue **alertas de error corregidas**, con 86.90 % de retroalimentación atendida.

La Tabla 2 muestra que los indicadores internos de la plataforma se relacionan con procesos de aprendizaje activo, especialmente cuando el estudiante revisa errores, atiende recomendaciones y avanza por rutas personalizadas. El valor más alto se observa en la retroalimentación atendida para alertas de error corregidas, lo cual sugiere que la plataforma pudo haber contribuido a desarrollar autorregulación matemática. Este hallazgo es importante porque el pensamiento lógico-matemático no se fortalece únicamente al responder correctamente, sino al comprender por qué una respuesta es incorrecta, comparar alternativas y reconstruir el procedimiento. La alta precisión en problemas contextualizados también indica que los estudiantes tuvieron mejores oportunidades para aplicar operaciones y razonamientos en situaciones cercanas a la realidad. La plataforma adaptativa, al presentar retos graduados y ajustar la dificultad según el desempeño, permitió que los estudiantes no permanecieran demasiado tiempo en ejercicios simples ni fueran expuestos abruptamente a tareas complejas sin preparación previa. Desde la perspectiva didáctica, esto favorece una zona de avance progresivo,

donde el estudiante recibe desafíos alcanzables y retroalimentación inmediata. Asimismo, las misiones de argumentación muestran un avance menor en comparación con otras destrezas, lo que sugiere que justificar procedimientos sigue siendo una habilidad que requiere mayor acompañamiento docente, diálogo matemático y socialización de estrategias.

Tabla 3

Validez de contenido y confiabilidad del instrumento de pensamiento lógico-matemático

Componente evaluado del instrumento	Índice V de Aiken	Alfa de Cronbach	Omega de McDonald	Criterio técnico	Decisión psicométrica
Identificación de patrones	0.91	0.87	0.88	Alta pertinencia	Aceptado
Razonamiento secuencial	0.89	0.88	0.89	Alta coherencia	Aceptado
Resolución de problemas	0.93	0.90	0.91	Muy alta relevancia	Aceptado
Inferencia matemática	0.90	0.89	0.90	Alta claridad	Aceptado
Argumentación lógica	0.88	0.86	0.87	Adecuada consistencia	Aceptado
Escala total	0.90	0.89	0.90	Muy confiable	Aceptado

Nota. El valor más significativo corresponde a resolución de problemas, con V de Aiken = 0.93 y Omega = 0.91.

La Tabla 3 evidencia que el instrumento diseñado para medir pensamiento lógico-matemático presenta indicadores adecuados de validez y confiabilidad. El valor global de Alfa de Cronbach de 0.89 permite sostener que los ítems tienen una consistencia interna muy confiable, es decir, que las preguntas guardan relación entre sí y miden de manera estable el constructo propuesto. El Omega de McDonald de 0.90 refuerza esta interpretación, pues constituye un indicador complementario de confiabilidad que resulta útil cuando se busca valorar la estabilidad de una escala educativa. La dimensión resolución de problemas alcanzó los valores más altos, lo que indica que los expertos consideraron sus ítems especialmente pertinentes y relevantes para medir el pensamiento lógico-matemático. Este resultado es coherente con el propósito del estudio, debido a que la resolución de problemas integra comprensión, análisis, inferencia, ejecución y evaluación del procedimiento. La dimensión argumentación lógica obtuvo valores ligeramente menores, aunque aceptables, lo que puede explicarse porque esta destreza es más compleja de medir mediante pruebas estructuradas, ya que involucra explicación,

justificación y uso del lenguaje matemático. En conjunto, los resultados psicométricos simulados permiten afirmar que el instrumento reúne condiciones técnicas suficientes para ser aplicado en un estudio cuasi experimental.

Tabla 4

Correlación de Pearson entre indicadores adaptativos y destrezas lógico-matemáticas posttest

Indicador de aprendizaje adaptativo	Destreza asociada	r de Pearson	p valor	Varianza explicada R²	Intensidad de asociación
Retroalimentación inmediata atendida	Resolución de problemas	0.72	0.000	0.52	Alta positiva
Rutas personalizadas completadas	Inferencia matemática	0.68	0.000	0.46	Moderada-alta positiva
Precisión en retos graduados	Identificación de patrones	0.64	0.001	0.41	Moderada positiva
Corrección de errores recurrentes	Argumentación lógica	0.59	0.002	0.35	Moderada positiva
Avance de nivel adaptativo	Razonamiento secuencial	0.66	0.000	0.44	Moderada-alta positiva
Tiempo activo en misiones	Transferencia de procedimientos	0.53	0.006	0.28	Moderada positiva

Nota. La asociación más significativa se observa entre retroalimentación inmediata atendida y resolución de problemas: $r = 0.72$; $p = 0.000$.

La Tabla 4 permite observar que los indicadores de interacción con la plataforma presentan correlaciones positivas con las destrezas lógico-matemáticas evaluadas. La correlación más alta se ubicó entre retroalimentación inmediata atendida y resolución de problemas, con $r = 0.72$, lo que indica una asociación alta y positiva. Esto significa que, en la simulación estadística, a mayor atención de la retroalimentación generada por la plataforma, mayor desempeño en resolución de problemas. Este resultado tiene sentido pedagógico, porque la retroalimentación inmediata ayuda al estudiante a identificar el punto exacto del error, corregir el procedimiento y ensayar nuevas estrategias. La varianza explicada de 0.52 indica que aproximadamente el 52 % de la variabilidad en la resolución de problemas podría asociarse con la retroalimentación atendida, aunque debe recordarse que correlación no implica causalidad directa. También se observa una correlación importante entre rutas personalizadas completadas e inferencia matemática, lo cual sugiere que la secuenciación adaptativa favorece la construcción gradual de relaciones lógicas. La asociación entre corrección de errores recurrentes y argumentación lógica fue moderada, lo que indica que corregir errores ayuda, pero no basta para argumentar; se requiere mediación docente, discusión entre pares y verbalización de

procedimientos. En general, estos resultados respaldan el valor de la correlación de Pearson dentro del estudio, porque permite demostrar que los indicadores de uso de la plataforma no son accesorios, sino que se vinculan con mejoras específicas en destrezas matemáticas.

Tabla 5

Distribución porcentual de niveles de logro por destreza lógico-matemática en el postest

Destreza evaluada	Inicio GC	Proceso GC	Logro esperado GC	Logro destacado GC	Inicio GE	Proceso GE	Logro esperado GE	Logro destacado GE
Identificación de patrones	20.00 %	42.50 %	30.00 %	7.50 %	5.00 %	17.50 %	47.50 %	30.00 %
Razonamiento secuencial	22.50 %	45.00 %	25.00 %	7.50 %	7.50 %	20.00 %	45.00 %	27.50 %
Resolución de problemas	25.00 %	47.50 %	22.50 %	5.00 %	2.50 %	15.00 %	50.00 %	32.50 %
Inferencia matemática	27.50 %	45.00 %	22.50 %	5.00 %	5.00 %	20.00 %	47.50 %	27.50 %
Argumentación lógica	30.00 %	42.50 %	22.50 %	5.00 %	7.50 %	22.50 %	45.00 %	25.00 %

Nota. El cambio más significativo se observa en resolución de problemas, donde el grupo experimental alcanza 82.50 % entre logro esperado y logro destacado.

La Tabla 5 permite analizar los resultados desde una perspectiva pedagógica de niveles de logro. El grupo experimental concentra mayores porcentajes en logro esperado y logro destacado, especialmente en resolución de problemas, identificación de patrones e inferencia matemática. Este comportamiento indica que la intervención con LógicaMath IA-RA Adaptativa no solo elevó medias estadísticas, sino que desplazó a una mayor proporción del grupo hacia niveles de desempeño superiores. En cambio, el grupo de control mantiene mayor concentración en los niveles inicio y proceso, lo cual sugiere que la metodología convencional produjo avances, pero no suficientes para movilizar significativamente a los estudiantes hacia desempeños destacados. Este tipo de análisis es importante porque, en educación básica, no basta con reportar promedios; también se requiere identificar cuántos estudiantes se ubican en niveles de logro que permiten tomar decisiones pedagógicas. Aunque la tabla no presenta una columna denominada estudiantes, los porcentajes muestran la distribución del desempeño de los grupos. La mejora del grupo experimental puede explicarse por la personalización de actividades, la

graduación de dificultad, la retroalimentación inmediata y el seguimiento de errores recurrentes. Sin embargo, la argumentación lógica sigue mostrando menor porcentaje de logro destacado, lo que permite interpretar que esta destreza requiere actividades complementarias de explicación oral, escritura matemática, discusión guiada y evaluación formativa cualitativa.

Tabla 6

Prueba t de Student para muestras independientes en el postest

Destreza lógico-matemática	Media GE	Media GC	Diferencia de medias	t	gl	p valor	IC 95 % de la diferencia
Identificación de patrones	17.45	13.20	4.25	8.71	78	0.000	[3.28; 5.22]
Razonamiento secuencial	16.90	12.85	4.05	7.63	78	0.000	[2.99; 5.11]
Resolución de problemas	17.20	12.60	4.60	9.18	78	0.000	[3.60; 5.60]
Inferencia matemática	16.55	12.35	4.20	7.96	78	0.000	[3.15; 5.25]
Argumentación lógica	16.10	12.15	3.95	7.12	78	0.000	[2.85; 5.05]

Nota. La diferencia más significativa se presenta en resolución de problemas, con $t = 9.18$ y $p = 0.000$.

La Tabla 6 presenta la comparación de medias entre el grupo experimental y el grupo de control mediante la prueba t de Student para muestras independientes. Los valores de $p = 0.000$ en todas las destrezas indican diferencias estadísticamente significativas a favor del grupo experimental. Esto permite rechazar la hipótesis nula de igualdad de medias y aceptar que, en los resultados simulados, el uso de la plataforma adaptativa se asocia con un rendimiento superior en pensamiento lógico-matemático. La mayor diferencia de medias se observa en resolución de problemas, donde el grupo experimental supera al grupo de control en 4.60 puntos. Este dato es relevante porque demuestra que el efecto de la intervención no se limita a tareas simples, sino que se expresa con mayor fuerza en una destreza integradora. El intervalo de confianza del 95 % no incluye el cero en ninguna dimensión, lo cual refuerza la consistencia estadística de las diferencias. Desde el punto de vista educativo, estos resultados sugieren que la plataforma permitió atender distintos ritmos de aprendizaje, ofrecer retos graduados y generar oportunidades de práctica diferenciada. La t de Student fue pertinente porque el estudio comparó dos grupos independientes en el postest; sin embargo, su interpretación debe complementarse con el tamaño del efecto, ya que una diferencia puede ser estadísticamente significativa sin ser necesariamente relevante en términos pedagógicos.

Tabla 7

Tamaño del efecto mediante d de Cohen según destrezas lógico-matemáticas

Destreza lógico-matemática	Diferencia media GE-GC	Desviación estándar combinada	d de Cohen	Magnitud del efecto	Relevancia pedagógica estimada
Identificación de patrones	4.25	2.17	1.96	Grande	Muy alta
Razonamiento secuencial	4.05	2.36	1.72	Grande	Muy alta
Resolución de problemas	4.60	2.21	2.08	Grande	Muy alta
Inferencia matemática	4.20	2.29	1.83	Grande	Muy alta
Argumentación lógica	3.95	2.43	1.63	Grande	Alta
Escala total lógico-matemática	4.21	2.29	1.84	Grande	Muy alta

Nota. El tamaño del efecto más alto corresponde a resolución de problemas, con $d = 2.08$. La Tabla 7 evidencia que el tamaño del efecto de la intervención es grande en todas las destrezas evaluadas. La d de Cohen más alta se ubica nuevamente en resolución de problemas, con un valor de 2.08, lo cual representa una magnitud muy alta de diferencia entre el grupo experimental y el grupo de control. Esta información es fundamental porque permite interpretar la relevancia práctica de los resultados. Mientras la t de Student indica si la diferencia entre grupos es estadísticamente significativa, la d de Cohen permite determinar cuán grande es esa diferencia en términos educativos. En este caso, los valores superiores a 0.80 se consideran grandes, por lo que los resultados simulados sugieren un efecto pedagógicamente fuerte de la plataforma adaptativa. La escala total obtuvo $d = 1.84$, lo cual indica que el impacto global sobre el pensamiento lógico-matemático sería considerable. La argumentación lógica presenta el menor tamaño del efecto relativo, aunque sigue siendo grande; esto confirma que la intervención también favorece procesos de justificación, pero probablemente necesita complementarse con actividades de diálogo matemático, exposición oral y escritura reflexiva. En conjunto, los tamaños del efecto permiten sostener que la plataforma no solo produjo diferencias numéricas, sino mejoras educativas con sentido práctico.

Tabla 8

Síntesis de hipótesis específicas según evidencia estadística simulada

Hipótesis específica	Evidencia principal	Resultado estadístico clave	Criterio de decisión	Interpretación sustantiva
La plataforma adaptativa mejora la identificación de patrones	Comparación posttest GE-GC	$t = 8.71$; $d = 1.96$	Se acepta	Mejora alta en reconocimiento de regularidades
La plataforma adaptativa fortalece el razonamiento secuencial	Comparación posttest GE-GC	$t = 7.63$; $d = 1.72$	Se acepta	Avance relevante en ordenamiento lógico
La plataforma adaptativa incrementa la resolución de problemas	Comparación posttest GE-GC	$t = 9.18$; $d = 2.08$	Se acepta	Mayor efecto de la intervención
La plataforma adaptativa favorece la inferencia matemática	Correlación y comparación de medias	$r = 0.68$; $d = 1.83$	Se acepta	Mejora en deducción de relaciones matemáticas
La plataforma adaptativa potencia la argumentación lógica	Diferencia posttest y corrección de errores	$r = 0.59$; $d = 1.63$	Se acepta	Avance alto, aunque requiere mediación docente
El uso adaptativo se relaciona con el desempeño total	Correlaciones de indicadores internos	r promedio = 0.64	Se acepta	Asociación positiva entre interacción adaptativa y logro

Nota. La hipótesis con mayor respaldo estadístico corresponde a resolución de problemas, por presentar simultáneamente $t = 9.18$ y $d = 2.08$.

La Tabla 8 resume la decisión estadística de las hipótesis específicas. Los resultados simulados permiten aceptar todas las hipótesis, debido a que las comparaciones de medias, correlaciones y tamaños del efecto favorecen al grupo experimental. La hipótesis más sólida corresponde a la resolución de problemas, ya que combina diferencia significativa, tamaño del efecto grande y coherencia con los indicadores de interacción adaptativa. Este resultado fortalece la idea de que la personalización basada en IA tiene mayor impacto cuando se aplica a tareas matemáticas que requieren análisis, decisión y verificación. La identificación de patrones y el razonamiento secuencial también muestran resultados altos, lo que sugiere que la plataforma fue efectiva para estructurar progresiones de dificultad. La inferencia matemática se relacionó de manera importante con las rutas personalizadas completadas, indicando que la adaptación progresiva puede ayudar a los estudiantes a establecer relaciones más complejas. Finalmente, la argumentación lógica fue aceptada, pero su interpretación requiere prudencia: aunque

mejoró de forma significativa, es una destreza que no depende únicamente de la plataforma, sino también de la mediación docente, la verbalización de procedimientos y la construcción social del razonamiento.

Discusión

Los resultados simulados del presente estudio permiten sostener que las plataformas de aprendizaje adaptativo basadas en inteligencia artificial pueden potenciar el pensamiento lógico-matemático en estudiantes de educación básica cuando se integran con una finalidad pedagógica clara, evaluación formativa y mediación docente. La mejora observada en el grupo experimental coincide con los planteamientos de Miao y Holmes (2023), quienes sostienen que la IA educativa debe responder a una visión centrada en el ser humano y al fortalecimiento de capacidades, no a la sustitución del docente. Asimismo, los hallazgos se relacionan con Miao y Cukurova (2024), debido a que el uso pedagógico de la IA exige competencias docentes para seleccionar herramientas, interpretar datos, actuar éticamente y diseñar experiencias adaptadas. También se vinculan con Miao, Shiohira y Lao (2024), quienes enfatizan que los estudiantes requieren competencias para interactuar con la IA de manera crítica y responsable. En este sentido, la plataforma LógicaMath IA-RA Adaptativa habría funcionado como un recurso de mediación que personaliza el aprendizaje, pero cuya efectividad depende de la intencionalidad didáctica del docente.

La mejora significativa en resolución de problemas guarda relación con los aportes de Létourneau, Deslandes Martineau y Charland (2025), quienes identifican que los sistemas de tutoría inteligente en educación K-12 pueden incidir positivamente en el aprendizaje, aunque sus efectos varían según diseño, duración y contexto. De manera similar, Dong et al. (2025) evidencian que la IA puede influir en el rendimiento académico, pero recomiendan analizar variables moderadoras como nivel educativo, área curricular y tipo de intervención. Los resultados también coinciden con Tlili et al. (2025), quienes señalan que el impacto de la IA educativa depende del modo de aprendizaje y del diseño pedagógico, no únicamente de la presencia tecnológica. Desde esta perspectiva, la diferencia obtenida en resolución de problemas puede explicarse porque la plataforma ofreció retos graduados, retroalimentación inmediata y oportunidades de corrección, elementos que favorecen la comprensión profunda y la transferencia de procedimientos. Los resultados de correlación de Pearson mostraron asociaciones positivas entre retroalimentación inmediata, rutas personalizadas y desempeño lógico-matemático. Este

hallazgo coincide con Cho (2025), quien sostiene que las plataformas basadas en IA pueden apoyar el aprendizaje matemático personalizado mediante métodos de adaptación que responden al desempeño del estudiante. También se relaciona con Khazanchi et al. (2025), quienes destacan que los sistemas basados en IA pueden fortalecer tanto el involucramiento cognitivo como el afectivo en matemáticas. Asimismo, Kwak (2025) sostiene que las plataformas adaptativas y los sistemas de tutoría inteligente pueden mejorar resultados frente a métodos tradicionales cuando se aplican con criterios de escalabilidad, seguimiento y ética. Por tanto, la asociación positiva encontrada no debe interpretarse como un efecto automático de la tecnología, sino como resultado de la interacción entre diagnóstico, retroalimentación, práctica personalizada y acompañamiento docente.

La mejora en identificación de patrones y razonamiento secuencial es coherente con Panqueban (2024), quien identifica que la IA en educación matemática se asocia con análisis del aprendizaje, personalización y automatización de retroalimentación. Asimismo, Nguyen (2025) reporta que la investigación reciente sobre IA en educación matemática se ha concentrado en aprendizaje personalizado, tutoría inteligente, entornos virtuales, chatbots y evaluación automatizada. Son (2024), desde el análisis de sistemas de tutoría inteligente en matemáticas, también resalta la importancia de estudiar cómo interactúan el estudiante, el contenido y la retroalimentación. En este estudio, los indicadores de rutas completadas y retos desbloqueados sugieren que la adaptación progresiva permitió organizar secuencias de aprendizaje con mayor precisión que una programación uniforme para todo el grupo.

Los hallazgos también se articulan con el contexto latinoamericano. La CEPAL (2024) advierte que la región presenta brechas en adopción e inversión en IA, por lo que la incorporación de plataformas adaptativas debe pensarse desde condiciones reales de conectividad, formación docente y equidad. Herrera (2024) plantea que las competencias digitales son indispensables en la transformación educativa de América Latina y el Caribe, especialmente porque las tecnologías digitales ya forman parte de las oportunidades sociales y productivas. En esa línea, Ortiz et al. (2025) señalan que la tecnología puede contribuir a maximizar aprendizajes, asegurar trayectorias educativas inclusivas y mejorar la gestión escolar, aunque su efectividad varía en contextos de bajos y medianos ingresos. Por tanto, los resultados favorables del grupo experimental no deben

conducir a una adopción acrítica de plataformas, sino a una implementación planificada, contextualizada y evaluada.

En el caso ecuatoriano, los resultados se relacionan con el Marco Curricular Competencial de Aprendizajes, que plantea una transformación educativa orientada a competencias, inclusión, mejoramiento de aprendizajes, formación docente y transformación digital (Ministerio de Educación del Ecuador, 2023). Asimismo, las orientaciones nacionales sobre IA recomiendan usarla para personalizar la enseñanza, ofrecer recursos adaptados, fomentar pensamiento crítico, apoyar la toma de decisiones pedagógicas y evitar riesgos de sesgo, dependencia o inequidad (Ministerio de Educación del Ecuador, 2024). Lima-Yarpaz (2025) también reporta que la aplicación de competencias matemáticas, digitales y socioemocionales en el currículo ecuatoriano requiere mayor contextualización y fortalecimiento docente. Estos aportes permiten interpretar que las plataformas adaptativas pueden ser pertinentes si se vinculan al currículo, a las destrezas con criterio de desempeño y a la evaluación formativa, no como actividades aisladas.

La prueba t de Student evidenció diferencias estadísticamente significativas en todas las destrezas evaluadas, mientras que la d de Cohen mostró tamaños del efecto grandes. Este resultado es consistente con la literatura reciente que recomienda no limitarse al p valor, sino complementar la significancia estadística con magnitud del efecto. Dong et al. (2025), Tlili et al. (2025), Huang et al. (2025) y Létourneau et al. (2025) coinciden en que la evaluación de la IA educativa debe considerar diseños experimentales o cuasi experimentales más rigurosos, tamaños de efecto, duración de intervención y características del contexto. En este artículo, el uso combinado de t de Student y d de Cohen permite argumentar que la diferencia entre grupos no solo sería estadísticamente significativa, sino también pedagógicamente relevante.

La argumentación lógica presentó mejoras significativas, aunque con menor efecto relativo frente a resolución de problemas e identificación de patrones. Este resultado dialoga con Li, Jiang, Chen, Fang, Wang y He (2023), quienes señalan que la resolución cooperativa de problemas matemáticos puede influir en el logro grupal, especialmente cuando los estudiantes explican procedimientos y contrastan estrategias. También se vincula con Filo (2024), quien destaca la necesidad de marcos de competencia en IA que involucren a docentes y estudiantes en procesos de co-creación. Desde esta perspectiva, la argumentación lógica no se fortalece únicamente con ejercicios adaptativos; requiere espacios de verbalización, diálogo, justificación escrita y retroalimentación humana. Por

ello, aunque la IA puede detectar errores y sugerir rutas, el docente sigue siendo fundamental para promover preguntas profundas, discusión matemática y construcción colectiva del razonamiento.

Los resultados también son compatibles con las advertencias de UNICEF (2025), Miao y Holmes (2023), y el Ministerio de Educación del Ecuador (2024), en cuanto a que la IA en educación básica debe proteger privacidad, equidad, seguridad y desarrollo integral de los estudiantes. Una plataforma adaptativa puede recopilar datos de interacción, ritmos de avance y errores frecuentes; sin embargo, esos datos deben utilizarse con fines pedagógicos legítimos y bajo criterios de transparencia. De lo contrario, la personalización puede transformarse en vigilancia, sesgo o dependencia tecnológica. En este sentido, el aporte del estudio no consiste en afirmar que la IA mejora automáticamente la matemática, sino en mostrar que, cuando se diseña una intervención con objetivos claros, instrumentos confiables y análisis estadístico adecuado, la IA puede convertirse en una herramienta didáctica valiosa para fortalecer destrezas lógico-matemáticas.

Finalmente, la discusión permite afirmar que el uso de plataformas adaptativas basadas en IA representa una línea de innovación educativa con potencial científico y práctico. Strielkowski et al. (2025) sostienen que el aprendizaje adaptativo impulsado por IA puede contribuir a modelos educativos sostenibles si se orienta a la personalización y a la mejora de resultados. Molina, Cobo, Pineda y Rovner (2024) advierten que la revolución de la IA en educación aún se encuentra en etapas tempranas, por lo que requiere evidencia, gobernanza y formación docente. Molina y Medina (2025) añaden que la adopción de IA en la región necesita adaptación a realidades sociales, económicas e infraestructurales. En consecuencia, los resultados simulados de este estudio aportan una propuesta metodológica y analítica para investigar la IA adaptativa en educación básica desde una perspectiva cuantitativa, ética y pedagógicamente fundamentada.

Conclusiones

Los resultados simulados del estudio permiten concluir que las plataformas de aprendizaje adaptativo basadas en inteligencia artificial pueden contribuir significativamente al fortalecimiento del pensamiento lógico-matemático en estudiantes de educación básica. La intervención con LógicaMath IA-RA Adaptativa mostró diferencias favorables en identificación de patrones, razonamiento secuencial, resolución de problemas, inferencia matemática y argumentación lógica. La combinación de análisis

descriptivo, correlación de Pearson, t de Student y d de Cohen permitió demostrar no solo diferencias estadísticas, sino también relevancia pedagógica del cambio, especialmente en resolución de problemas, donde se observó el mayor tamaño del efecto.

Como contribución científica, el artículo propone una ruta metodológica para evaluar plataformas adaptativas con IA en educación básica desde un enfoque cuasi experimental y descriptivo-correlacional. Además, evidencia que la IA educativa debe ser comprendida como una mediación pedagógica orientada a personalizar el aprendizaje, retroalimentar procesos y apoyar decisiones docentes, no como reemplazo del profesor. La implementación responsable de este tipo de plataformas exige formación docente, protección de datos, equidad de acceso, alineación curricular y evaluación permanente de sus efectos sobre el desarrollo cognitivo, ético y social de los estudiantes.

Referencias

- Al Yaarubi, M. (2025). AI-powered adaptive learning in mathematics education: A bibliometric analysis of studies published in Scopus 2015–2024. *International Journal of Academic Research in Business and Social Sciences*, 15(12). DOI: 10.6007/IJARBSS/v15-i12/27141
- CEPAL. (2024). *Superar las trampas del desarrollo de América Latina y el Caribe en la era digital: El potencial transformador de las tecnologías digitales y la inteligencia artificial*. Comisión Económica para América Latina y el Caribe.
- Cho, M. K. (2025). Analyzing AI-based educational platforms for supporting personalized mathematics learning. *International Electronic Journal of Mathematics Education*, 20(4), em0847. DOI: 10.29333/iejme/16664
- Dong, L., et al. (2025). Examining the effect of artificial intelligence in relation to students' academic achievement: A meta-analysis. *Smart Learning Environments*.
- Filo, Y. (2024). An artificial intelligence competency framework for teachers and students. *European Journal of Open, Distance and E-Learning*. DOI: 10.2478/eurodl-2024-0012
- Herrera, P. (2024). *Educación y desarrollo de competencias digitales en América Latina y el Caribe*. Comisión Económica para América Latina y el Caribe.
- Huang, X., et al. (2025). Effects of intelligent tutoring systems on educational outcomes: A meta-analytic review. *Computers and Education: Artificial Intelligence*.
- Ilić, J. (2024). The impact of intelligent tutoring systems and artificial intelligence on students' motivation and achievement in STEM education: A systematic review.

International Journal of Cognitive Research in Science, Engineering and Education.

- Khazanchi, R., et al. (2025). The effect of AI-based systems on mathematics achievement and engagement: A meta-analysis. *Journal of Computer Assisted Learning*. DOI: 10.1111/jcal.13098
- Kwak, M. (2025). The effectiveness of AI-driven tools in improving student learning outcomes compared to traditional methods. *Issues in Information Systems*, 26(4), 233–247. DOI: 10.48009/4_iis_2025_120
- Létourneau, A., Deslandes Martineau, M., & Charland, P. (2025). A systematic review of AI-driven intelligent tutoring systems in K-12 education. *npj Science of Learning*, 10. DOI: 10.1038/s41539-025-00320-7
- Li, Y., Jiang, C., Chen, Z., Fang, J., Wang, C., & He, X. (2023). Peer tutoring models in cooperative learning of mathematical problem-solving in flipped classroom and their influence on group achievement. *Education and Information Technologies*, 28, 6595–6618. DOI: 10.1007/s10639-022-11429-2
- Lima-Yarpaz, J. (2025). Pertinencia del currículo priorizado con énfasis en competencias: Perspectivas docentes sobre la enseñanza de matemáticas en Bachillerato en Ciencias. *Revista Cátedra*, 8(2), 56–74.
- Miao, F., & Cukurova, M. (2024). *AI competency framework for teachers*. UNESCO. DOI: 10.54675/ZJTE2084
- Miao, F., & Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO.
- Miao, F., Shiohira, K., & Lao, N. (2024). *AI competency framework for students*. UNESCO. DOI: 10.54675/JKJB9835
- Ministerio de Educación del Ecuador. (2021). *Currículo priorizado con énfasis en competencias comunicacionales, matemáticas, digitales y socioemocionales*. Ministerio de Educación.
- Ministerio de Educación del Ecuador. (2023). *Marco curricular competencial de aprendizajes*. Ministerio de Educación.
- Ministerio de Educación del Ecuador. (2024). *Orientaciones para el uso pedagógico de herramientas de inteligencia artificial*. Ministerio de Educación.
- Mina, A., Raptis, K., Revelo, P., Changoluisa, K., & Coronel, J. (2023). Currículo priorizado con énfasis en competencias digitales, comunicacionales, matemáticas

- y socioemocionales en el aprendizaje de los estudiantes del Ecuador. *MQRInvestigar*, 7(1), 1741–1756. DOI: 10.56048/MQR20225.7.1.2023.1741-1756
- Molina, E., Cobo, C., Pineda, J., & Rovner, H. (2024). *AI revolution in education: What you need to know*. World Bank.
- Molina, E., & Medina, E. (2025). *AI revolution in higher education: What you need to know*. World Bank.
- Nguyen, D. T. (2025). Artificial intelligence in mathematics education: Bibliometric analysis for the period 2020–2025. *International Electronic Journal of Mathematics Education*.
- OECD. (2023). *PISA 2022 Results Volume I: The state of learning and equity in education*. OECD Publishing. DOI: 10.1787/53f23881-en
- OECD. (2024). *PISA 2022 Results Volume III: Creative minds, creative schools*. OECD Publishing. DOI: 10.1787/765ee8c2-en
- Ortiz, E. A., et al. (2025). *AI and education: Building the future through digital transformation*. Inter-American Development Bank.
- Panqueban, D. (2024). Artificial intelligence in mathematics education. *Revista Latinoamericana de Investigación en Matemática Educativa*.
- Son, T. (2024). Intelligent tutoring systems in mathematics education. *Computers*, 13(10), 270. DOI: 10.3390/computers13100270
- Strielkowski, W., et al. (2025). AI-driven adaptive learning for sustainable educational transformation. *Sustainable Development*. DOI: 10.1002/sd.3221
- Tlili, A., et al. (2025). Investigating the effect of artificial intelligence in education on students' learning achievement: A meta-analysis and research synthesis. *Information Development*. DOI: 10.1177/026666669241304407
- UNICEF. (2025). *Guidance on AI and children*. UNICEF Innocenti.
- UNESCO. (2023). *Global education monitoring report 2023: Technology in education: A tool on whose terms?* UNESCO.
- World Bank. (2025). *AI revolution in education: What you need to know*. World Bank.

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés