

Impacto del aprendizaje híbrido adaptativo mediado por inteligencia artificial en competencias digitales y rendimiento en matemáticas

Impact of AI-mediated adaptive hybrid learning on digital skills and performance in mathematics

- 1 Carlitos Alberto Guano Cárdenas  <https://orcid.org/0000-0002-7571-2972>
Universidad Politécnica Estatal del Carchi (UPEC), Tulcán, Ecuador. Magister en Gerencia en Sistemas
carlos.guano@upec.edu.ec
- 2 Nelson Germán Heredia Enríquez  <https://orcid.org/0000-0001-5219-794X>
Universidad Politécnica Estatal del Carchi (UPEC), Tulcán, Ecuador. Magister en Administración de Negocios
nelson.heredia@upec.edu.ec
- 3 César Armando Enríquez Montenegro  <https://orcid.org/0000-0003-0510-8590>
Universidad Politécnica Estatal del Carchi (UPEC), Tulcán, Ecuador. Magister en Educación a Distancia y Abierta
cesar.enriquez@upec.edu.ec
- 4 Jenny Patricia Osejo Domínguez  <https://orcid.org/0009-0000-2086-5667>
Universidad Politécnica Estatal del Carchi (UPEC), Tulcán, Ecuador. Magister en Gerencia Educativa
jenny.osejo@upec.edu.ec

Artículo de Investigación Científica y Tecnológica

Enviado: 12/11/2025

Revisado: 12/12/2025

Aceptado: 27/01/2026

Publicado: 03/04/2026

DOI: <https://doi.org/10.33262/cienciadigital.v10i2.3637>

Cítese:

Guano Cárdenas, C. A., Heredia Enríquez, N. G., Enríquez Montenegro, C. A., & Osejo Domínguez, J. P. (2026). Impacto del aprendizaje híbrido adaptativo mediado por inteligencia artificial en competencias digitales y rendimiento en matemáticas. *Ciencia Digital*, 10(2), 6-19. <https://doi.org/10.33262/cienciadigital.v10i2.3637>

**Ciencia
Digital**

CIENCIA DIGITAL, es una revista multidisciplinaria, trimestral, que se publicará en soporte electrónico tiene como misión contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://cienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec.

Esta revista está protegida bajo una licencia *Creative Commons Atribución-NoComercial-CompartirIgual 4.0 International*. Copia de la licencia: <https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>.



Palabras claves: Inteligencia artificial, aprendizaje híbrido adaptativo, competencias digitales, ética en IA, rendimiento académico.

Resumen: La Inteligencia Artificial (IA) ha impulsado la evolución de los modelos de aprendizaje híbrido adaptativo en la educación superior al permitir la retroalimentación inmediata, el ajuste dinámico de actividades y la personalización basada en datos. En los cursos de nivelación de Matemáticas de la UPEC, estas funcionalidades son particularmente relevantes debido a las brechas en las competencias digitales de los estudiantes y la variabilidad en el rendimiento académico. **Objetivo:** Analizar el impacto de un modelo de aprendizaje híbrido adaptativo mediado por IA en las competencias digitales de los estudiantes (DigCompEdu adaptado al contexto matemático) y en el rendimiento académico (pre-post), así como examinar las relaciones entre retroalimentación, aprendizaje adaptativo y el uso ético de la IA. **Metodología:** Se realizó un estudio cuantitativo cuasiexperimental con diseño pretest-postest sin grupo control en dos cohortes de nivelación ($N = 500$). Se administraron pruebas diagnósticas y finales para medir el rendimiento, y se utilizó un instrumento de percepción basado en DigCompEdu para evaluar las competencias digitales. Se realizaron estadísticas descriptivas, correlaciones de Pearson, ANOVA de medidas repetidas y regresión múltiple de la ganancia académica. **Resultados:** El instrumento demostró una alta confiabilidad interna ($\alpha \geq 0,74 - 0,98$). Todas las dimensiones de competencia digital obtuvieron puntuaciones medias superiores a 4.0, con fuertes correlaciones entre índices ($p < ,001$). Sin embargo, el modelo de regresión múltiple no predijo significativamente la ganancia académica ($R^2 = 0,008; p > ,05$), lo que indica que las percepciones favorables y las competencias digitales fortalecidas no se tradujeron directamente en un mejor rendimiento. **Conclusión:** Los entornos de aprendizaje híbrido adaptativo mediados por IA mejoran las competencias digitales y son valorados positivamente por los estudiantes, pero su efecto directo sobre el rendimiento académico no es automático. Se requiere un diseño instruccional robusto, métricas de aprendizaje objetivas y un mayor control experimental, junto con prácticas éticas alineadas con estándares internacionales. **Área de estudio general:** Educación. **Área de estudio específica:** Educación matemática y tecnología educativa. **Tipo de estudio:** Artículo original.

Keywords: Artificial intelligence, adaptive hybrid learning, digital competence, AI ethics, academic performance.

Abstract: Introduction: Artificial Intelligence (AI) has driven the evolution of adaptive hybrid learning models in higher education by enabling immediate feedback, dynamic adjustment of activities, and data-driven personalization. In UPEC's Mathematics leveling courses, these functionalities are particularly relevant due to gaps in students' digital competences and variability in academic performance. **Objective:** To analyze the impact of an AI-mediated adaptive hybrid learning model on students' digital competences (DigCompEdu adapted to the mathematical context) and academic performance (pre-post), as well as to examine the relationships between feedback, adaptive learning, and the ethical use of AI. **Methodology:** A quantitative quasi-experimental pretest-posttest study without a control group was conducted with two leveling cohorts (N = 500). Diagnostic and final tests were administered to measure performance, and a perception instrument based on DigCompEdu was used to assess digital competences. Descriptive statistics, Pearson correlations, repeated measures ANOVA, and multiple regression of academic gain were performed. **Results:** The instrument demonstrated high internal reliability ($\alpha \geq 0,74 - 0,98$). All dimensions of digital competence obtained mean scores above 4.0, with strong correlations between indices ($p < ,001$). However, the multiple regression model did not significantly predict academic gain ($R^2 = 0,008$; $p > ,05$), indicating that favorable perceptions and strengthened digital competences did not directly translate into improved performance. **Conclusion:** AI-mediated adaptive hybrid learning environments enhance digital competences and are positively valued by students, but their direct effect on academic performance is not automatic. Robust instructional design, objective learning metrics, and greater experimental control are required, alongside ethical practices aligned with international standards. **General area of study:** Education. **Specific area of study:** Mathematics education and educational technology. **Type of study:** Original article.

1. Introducción

En la última década la Inteligencia Artificial (IA) se consolidó como un eje trans-

formador de la educación superior debido a su capacidad para personalizar experiencias (Lubguban & Bauyot, 2025), ajustar dinámicamente la dificultad y ofrecer retroalimen-

tación inmediata basada en datos de desempeño estudiantil. Las revisiones de literatura y artículos de síntesis coinciden en que la IA, tanto en su vertiente de análisis de datos como en sistemas interactivos, potenciaron funciones tales como el perfilamiento del estudiante, la automatización de diagnósticos formativos y la recomendación de rutas de aprendizaje, con efectos positivos en escenarios universitarios cuando existe alineación pedagógica explícita (Chen et al., 2020; Zawacki-Richter et al., 2019). Este conjunto de capacidades aceleró la transición hacia modelos híbrido-adaptativos que integran presencialidad, virtualidad y analíticas de aprendizaje, permitiendo a docentes y estudiantes tomar decisiones instruccionales con mayor oportunidad y pertinencia (Gli-gorea et al., 2023; Hariyanto & Maharani, 2025).

En este mismo marco el aprendizaje personalizado impulsado por IA se reconoce como una de las innovaciones más relevantes para mejorar la eficiencia educativa. Según Cao et al. (2025) los sistemas adaptativos fundamentados en algoritmos avanzados, analíticas de aprendizaje y mecanismos de retroalimentación continua pueden ajustar dinámicamente las actividades y optimizar los resultados académicos, favoreciendo incrementos sostenidos en participación, autonomía y progreso formativo. Los autores reportan que estos enfoques reducen tiempos de aprendizaje y mejoran el rendimiento en comparación con métodos tradicionales, aunque su efectividad depende de la calidad del diseño instruccional, la alineación pedagógica, la gestión ética de datos

y la formación docente (Maphalala & Ajani, 2025; Fernández et al., 2025; Martínez et al., 2019). Esta perspectiva refuerza la pertinencia de estudiar la IA no solo como un recurso tecnológico, sino como una arquitectura pedagógica capaz de transformar procesos formativos si se implementa con criterios de calidad.

En el campo de la educación matemática, la literatura ocupa un lugar estratégico por el nivel de demanda cognitiva de la disciplina y la importancia de la secuenciación de tareas y el andamiaje. Las síntesis Sistemáticas sobre Tutorías Inteligentes (ITS) y sistemas adaptativos muestran que, cuando se integra retroalimentación contingente, modelado del aprendiz y ajustes dinámicos de la dificultad, se observan mejoras en comprensión conceptual, fluidez procedimental y estrategias de resolución de problemas (Niño-Rojas et al., 2024; Son, 2024). Asimismo, la cartografía sistemática evidencia avances en diagnóstico formativo y reducción de carga cognitiva a través de la personalización de secuencias y recomendaciones de práctica, aunque persisten desafíos de escalabilidad, uso responsable y consistencia evaluativa (Ezzaim et al., 2023; Chassignol et al., 2018).

El modelo híbrido-adaptativo se define como una arquitectura que combina modalidades presenciales, semipresenciales y virtuales con mecanismos de ajuste dinámico de actividades, retroalimentación en tiempo real y personalización basada en analíticas de aprendizaje. Este modelo aprovecha trazas de interacción (tiempos, intentos, erro-

res, aciertos) para recomendar contenidos, variar el nivel de dificultad, ofrecer pistas y modular el ritmo de progresión (Chen et al., 2020; Gligorea et al., 2023; García et al., 2025). En el caso de Matemáticas, su efectividad depende de la calidad del andamiaje y de la secuencia de tareas, de modo que los ITS y los sistemas adaptativos funcionan mejor cuando la complejidad instruccional se ajusta explícitamente al desempeño del estudiante (Koedinger et al., 2014; Niño-Rojas et al., 2024). No obstante, el impacto sobre el rendimiento académico no es automático ni lineal, ya que depende del diseño de actividades, la sensibilidad de las pruebas pre y post test, la validez de los instrumentos de percepción y la consistencia en los criterios evaluativos (Zawacki-Richter et al., 2019; Chen et al., 2020). Esto exige prestar atención a la operacionalización de variables, la fiabilidad de subescalas y la posible multicolinealidad entre retroalimentación y adaptatividad (Gligorea et al., 2023).

La consolidación de la IA en educación superior también demanda marcos de ética y gobernanza que garanticen equidad, transparencia, protección de datos y supervisión humana. La recomendación sobre la ética de la IA de la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO, 2021) establece principios para el diseño e integración responsable de sistemas que operan con datos sensibles, subrayando la trazabilidad de decisiones y la necesidad de políticas institucionales que resguarden derechos de estudiantes y docentes. De forma complementaria, la literatura en ética algorítmica enfatiza la

evaluación de justicia, responsabilidad institucional y explicabilidad como condiciones fundamentales para alinear la tecnología con los fines formativos (Whittlestone et al., 2019; González et al., 2025). Paralelamente, el desarrollo de la competencia digital adquiere relevancia estratégica: en educación superior se concibe como la capacidad de integrar tecnologías con criterios pedagógicos, técnicos y éticos, articulando selección de herramientas, gestión de datos, diseño de actividades, evaluación y análisis de consecuencias (Castañeda et al., 2018). Integrar IA desde esta competencia implica que la personalización y la retroalimentación funcionen como medios subordinados a objetivos curriculares, evitando sesgos, minimizando riesgos y asegurando aprendizajes medibles y transferibles (Zawacki-Richter et al., 2019; Chen et al., 2020).

Los cursos de nivelación en matemáticas representan un escenario crítico de transición hacia la vida universitaria, en el que convergen heterogeneidad de perfiles de ingreso, brechas en razonamiento y hábitos de estudio, y variabilidad en alfabetización digital. En estos contextos, la implementación de modelos híbrido adaptativos mediada por IA es pertinente por tres razones: (1) permite ajustar la complejidad de tareas según desempeño, incrementando la oportunidad pedagógica; (2) favorece el seguimiento temprano de dificultades y la retroalimentación formativa, apoyando la toma de decisiones docentes; (3) brinda un entorno idóneo para el desarrollo de competencias digitales aplicadas al estudio de contenidos matemáticos (Niño Rojas et al., 2024; Son, 2024; Gligo-

rea et al., 2023). No obstante la pertinencia pedagógica no garantiza por sí sola, mejoras en rendimiento. Las síntesis subrayan que si el diseño instruccional no plantea alineación clara entre objetivos, tareas, retroalimentación y criterios de evaluación, los beneficios sobre el desempeño pueden diluirse o manifestarse sólo en indicadores de participación y percepción (Zawacki Richter et al., 2019; Chen et al., 2020). Por ello el análisis del impacto debe contemplar indicadores objetivos (p. ej., pruebas diagnósticas/finales), junto a instrumentos de percepción fiables que permitan estudiar relaciones entre dimensiones digitales y resultados académicos (Gligorea et al., 2023).

Aunque la literatura internacional reporta avances consistentes en personalización, tutorías inteligentes y plataformas adaptativas, persisten brechas de evidencia respecto de cómo las competencias digitales, la retroalimentación y el aprendizaje adaptativo se asocian con el rendimiento en situaciones reales de nivelación universitaria, especialmente cuando se trabaja con cohortes numerosas y diseños cuasiexperimentales sin grupo control (Zawacki Richter et al., 2019; Chen et al., 2020). Adicionalmente, las investigaciones advierten que el uso de subescalas estrechamente relacionadas (p. ej., retroalimentación y adaptatividad), puede inducir multicolinealidad, reduciendo la capacidad de los modelos de regresión para identificar predictores independientes del rendimiento (Gligorea et al., 2023). En este sentido se requiere evidencia localizada que analice la ganancia pre-post en cursos de nivelación, incorporando instrumentos adap-

tados al contexto matemático y reportando fiabilidad, descriptivos y asociaciones entre dimensiones digitales. La calidad de esta evidencia depende, por un lado, de la operacionalización clara de variables; y, por otro, de la consistencia de la intervención (duración, secuencia, tareas, mecanismos de feedback) y del reporte ético alineado a marcos internacionales (UNESCO, 2021; Whittlestone et al., 2019).

A partir de los antecedentes revisados, se delimita el problema científico de la investigación de la siguiente manera: En los cursos de nivelación en Matemáticas, la integración de modelos híbrido adaptativos mediada por IA fortalece las competencias digitales del estudiantado y genera percepciones favorables, pero no existe evidencia concluyente sobre su capacidad para predecir la ganancia académica (pre-post) medida a través de pruebas de rendimiento, especialmente cuando las dimensiones del instrumento (retroalimentación y adaptatividad) presentan altas correlaciones que podrían afectar el poder explicativo de los modelos. Este problema se sustenta en tres tensiones: (1) Validez: la fiabilidad de subescalas puede ser alta, pero la superposición conceptual compromete la predicción del rendimiento (Gligorea et al., 2023). (2) Sensibilidad: las pruebas pre-post deben ser sensibles al progreso real; su diseño y alineación con la intervención son determinantes (Zawacki Richter et al., 2019; Chen et al., 2020). (3) Diseño: la ausencia de grupo control limita inferencias causales; se requieren diseños robustos y métricas objetivas acompañadas de analíticas de aprendizaje para mejorar el

seguimiento (Hariyanto & Maharani, 2025; Yuensook et al., 2024).

La presente investigación se justifica por su relevancia pedagógica, metodológica y ética. En el plano pedagógico, aporta evidencia sobre la relación entre competencias digitales y rendimiento en un entorno universitario real de nivelación en matemáticas, donde confluyen brechas de ingreso y exigencias de rápida adaptación a la vida académica (Niño Rojas et al., 2024; Son, 2024). En el plano metodológico, describe de forma transparente un diseño cuasiexperimental pre-post sin grupo control, reporta fiabilidad de subescalas, correlaciones e intenta modelar la ganancia académica mediante regresión múltiple, incorporando la discusión sobre multicolinealidad y sensibilidad de instrumentos (Ramos, 2021; Gligorea et al., 2023; Zawacki Richter et al., 2019). En el plano ético se alinea con la UNESCO (2021) y la agenda de ética de algoritmos relativa a equidad, transparencia, protección de datos y supervisión humana, promoviendo prácticas responsables en la adopción de IA en educación superior (UNESCO, 2021; Whittlestone et al., 2019; González et al., 2025). Además, el estudio ofrece insumos para la mejora institucional: andamiajes explícitos, evaluaciones sensibles al progreso, métricas objetivas de uso (trazas, tiempo de interacción, rutas seguidas) y formación docente en competencia digital (Castañeda et al., 2018; Chen et al., 2020).

Objetivo general: analizar el impacto de un modelo híbrido adaptativo mediado por IA

sobre las competencias digitales del estudiantado (DigCompEdu adaptado) y el rendimiento académico (pre-post) en cursos de nivelación de Matemáticas de la UPEC, y examinar las relaciones entre retroalimentación, aprendizaje adaptativo y uso ético de la IA. Objetivos específicos: (1) Describir la fiabilidad interna de las subescalas del instrumento de competencias digitales y uso ético de IA. (2) Caracterizar las tendencias de percepción en alfabetización digital aplicada, resolución de problemas con IA, retroalimentación y aprendizaje adaptativo, y uso ético de IA. (3) Comparar los resultados de rendimiento entre pretest y post test para estimar la ganancia académica. (4) Explorar las correlaciones entre dimensiones de competencias digitales e indicadores de rendimiento. (5) Evaluar la capacidad predictiva de las competencias digitales y del uso ético de IA sobre la ganancia académica, mediante regresión múltiple, considerando multicolinealidad y sensibilidad de instrumentos. (6) Identificar implicaciones didácticas y éticas para diseños instruccionales futuros y para la gobernanza institucional del uso de IA en la educación superior.

2. Metodología

La investigación se desarrolló bajo un enfoque predominantemente cuantitativo, orientado a analizar la relación entre las competencias digitales del estudiantado y el rendimiento académico en el marco de un modelo híbrido - adaptativo mediado por Inteligencia Artificial (IA). El diseño correspondió a un estudio cuasiexperimental pretest y post test sin grupo control, aplicado en dos co-

hortes de estudiantes matriculados en el curso Introducción a la Matemática durante los periodos 2025 A y 2025 B. Este tipo de diseño resulta adecuado para contextos educativos reales donde no es posible la asignación aleatoria y permite examinar variaciones intra sujeto luego de una intervención pedagógica (Ramos Galarza, 2021).

La población estuvo constituida por los 500 estudiantes inscritos en el centro de nivelación de la Universidad Politécnica Estatal del Carchi (UPEC). Se aplicaron criterios de inclusión que exigían: participación voluntaria, matrícula activa en la asignatura, completitud del pretest y post test, y respuesta íntegra al cuestionario de percepción. Se excluyeron quienes se retiraron de la institución o dejaron instrumentos incompletos. Este procedimiento buscó asegurar la validez interna del estudio eliminando casos con datos faltantes o participación irregular.

La intervención pedagógica consistió en la implementación de un modelo híbrido adaptativo mediante actividades presenciales, semipresenciales y virtuales, apoyadas por herramientas de IA orientadas al ajuste dinámico de tareas, la retroalimentación inmediata y la generación de rutas personalizadas de aprendizaje. Según Chen et al. (2020) estas funciones permiten optimizar el seguimiento del desempeño y aumentar la pertinencia pedagógica de las actividades académicas. Esta lógica coincide con lo planteado por Koedinger et al. (2014) quienes explican que los sistemas adaptativos ajustan la complejidad instruccional en función del desempeño del estudiante. Para ga-

rantizar consistencia pedagógica, las herramientas digitales utilizadas se seleccionaron en función de su equivalencia funcional respecto a retroalimentación, resolución de problemas y andamiaje adaptativo.

Para medir el rendimiento académico se aplicaron una prueba diagnóstica inicial (pretest) y una prueba final (post test), diseñadas para evaluar contenidos fundamentales de razonamiento matemático. Asimismo, se empleó un instrumento estructurado de percepción basado en el marco Dig-CompEdu, adaptado al contexto matemático universitario, con cuatro dimensiones: alfabetización digital aplicada, resolución de problemas con IA, retroalimentación y aprendizaje adaptativo, y uso ético de la IA. La fiabilidad interna se estimó mediante el coeficiente Alfa de Cronbach, cuyos valores oscilaron entre $\alpha = 0,74$ y $\alpha = 0,98$, considerados adecuados para instrumentos de investigación educativa (Gligorea et al., 2023).

Finalmente, se dio cumplimiento integral a los principios éticos establecidos por la UNESCO (2021) para garantizar un uso responsable y seguro de la inteligencia artificial en entornos educativos. Este cumplimiento incluyó la obtención de consentimiento informado por parte de todos los participantes, la aplicación de protocolos estrictos de protección y confidencialidad de datos personales, la presencia de supervisión humana durante todo el proceso formativo, y la transparencia respecto a los objetivos, alcances y condiciones de la intervención mediada por IA. Asimismo, se promovió un ambiente for-

mativo en el que la equidad, la seguridad y la trazabilidad de las decisiones asistidas por IA fueron consideradas elementos fundamentales para resguardar derechos y asegurar la integridad del proceso investigativo.

3. Resultados

La fiabilidad del instrumento presentó niveles adecuados y elevados de consistencia interna en todas las dimensiones analizadas. Como se muestra en la Tabla 1, los coeficientes Alfa de Cronbach obtenidos para las dimensiones de alfabetización digital aplicada a Matemáticas, resolución de problemas matemáticos con apoyo de inteligencia artificial, retroalimentación y mejora del aprendizaje, aprendizaje adaptativo y uso ético de la inteligencia artificial superaron ampliamente el umbral mínimo recomendado ($\alpha \geq 0,70$). Estos resultados evidencian una alta coherencia interna entre los ítems que conforman cada dimensión, lo que respalda la fiabilidad del cuestionario aplicado en el contexto de entornos híbridos adaptativos para la enseñanza mediado por inteligencia artificial en matemáticas.

Tabla 1: Fiabilidad del instrumento mediante el coeficiente Alfa de Cronbach

Dimensión	Número de ítems	Alfa de Cronbach
Uso ético de la inteligencia artificial	5	0.94
Alfabetización digital aplicada a Matemáticas	5	0.74
Resolución de problemas matemáticos con apoyo de IA	5	0.88
Retroalimentación y mejora del aprendizaje	5	0.98
Aprendizaje adaptativo	5	0.98
Instrumento global	25	0.98

Nota. datos obtenidos en el estudio (2025)

En particular, los índices de alfabetización digital aplicada a Matemáticas ($M = 4.67$) y resolución de problemas matemáticos con apoyo de IA ($M = 4.61$) alcanzaron las medias más elevadas, lo que sugiere que los estudiantes reconocen a la IA como una herramienta eficaz para comprender conceptos matemáticos, analizar procedimientos y fortalecer estrategias de resolución. Asimismo, los índices de uso ético de la inteligencia artificial ($M = 4.23$), retroalimentación y mejora del aprendizaje ($M = 4.23$) y aprendizaje adaptativo ($M = 4.24$) evidencian una percepción positiva respecto al empleo responsable de la IA, la utilidad del feedback automatizado y el fortalecimiento de la autonomía del estudiante en entornos educativos mediados por tecnologías digitales.

Tabla 2: Estadísticos descriptivos de los índices analizados

Índice	Media
Uso ético de la inteligencia artificial	4.23
Alfabetización digital aplicada a Matemáticas	4.67
Resolución de problemas matemáticos con apoyo de IA	4.61
Retroalimentación y mejora del aprendizaje	4.23
Aprendizaje adaptativo	4.24

Nota. Escala Likert de 1 (totalmente en desacuerdo) a 5 (totalmente de acuerdo). Fuente: Elaboración propia a partir de los datos obtenidos en el estudio (2025).

El análisis de correlación de Pearson evidenció asociaciones positivas, altas y estadísticamente significativas entre todos los índices analizados ($p < .001$). Como se muestra en la Tabla 3, lo que sugiere una fuerte interrelación entre las dimensiones que conforman el modelo de aprendizaje híbrido y adaptativo mediado por inteligencia artificial.

En particular, se identificaron correlaciones muy altas entre el uso ético de la inteligencia artificial y la alfabetización digital aplicada a Matemáticas ($r = .83$), así como con la retroalimentación y mejora del aprendizaje ($r = .96$) y el aprendizaje adaptativo ($r = .95$). Estos resultados indican que una comprensión ética y responsable del uso de la IA se asocia estrechamente con el desarrollo de competencias digitales y con la adopción de estrategias de aprendizaje autónomas y adaptativas.

Asimismo, la retroalimentación y mejora del aprendizaje presentó una correlación extremadamente alta con el aprendizaje adaptativo ($r = .99$), lo que evidencia la estrecha relación conceptual y funcional entre ambos constructos en entornos educativos mediados por inteligencia artificial. Finalmente, la alfabetización digital aplicada a Matemáticas mostró una correlación alta con la resolución de problemas matemáticos con apoyo de IA ($r = .77$), lo que refuerza la importancia de las competencias digitales para el aprovechamiento pedagógico de herramientas de inteligencia artificial en la enseñanza universitaria de Matemáticas.

Tabla 3: Matriz de correlaciones de Pearson entre los índices analizados

Índice	1	2	3	4	5
1. Uso ético de la IA	—				
2. Alfabetización digital aplicada a Matemáticas	.83**	—			
3. Resolución de problemas con apoyo de IA	.68**	.77**	—		
4. Retroalimentación y mejora del aprendizaje	.96**	.85**	.66**	—	
5. Aprendizaje adaptativo	.95**	.86**	.66**	.99**	—

Nota. Todas las correlaciones son significativas ($p < .001$). Análisis estadístico realizado en RStudio.

Se estimó un modelo de regresión lineal múltiple con el objetivo de analizar la capacidad predictiva del uso ético de la inteligencia artificial, la alfabetización digital, la resolución de problemas con IA, la retroalimentación digital y el aprendizaje adaptativo sobre la ganancia académica de los estudiantes. Como se muestra en la Tabla 4 los resultados indicaron que el modelo no fue estadísticamente significativo, $F(5, 494) = 0.84$, $p = .52$, explicando un porcentaje mínimo de la varianza en la ganancia académica ($R^2 = .008$). Ninguna de las variables predictoras mostró un efecto significativo individual ($p > .05$).

Estos hallazgos sugieren que, si bien los estudiantes presentan valoraciones altamente positivas sobre el uso de la inteligencia artificial en el aprendizaje de Matemáticas, dichas percepciones no se traducen directamente en incrementos cuantificables del rendimiento académico medido a través de la ganancia de puntaje.

Tabla 4: Modelo de regresión lineal para la predicción de la ganancia académica

Predictor	B	EE	t	p
Uso ético de IA	0.06	0.22	0.26	.79
Alfabetización digital	0.46	0.33	1.38	.17
Resolución de problemas	-0.11	0.21	-0.52	.60
Retroalimentación	-0.64	0.84	-0.76	.45
Aprendizaje adaptativo	0.40	0.80	0.50	.62

Nota. $R^2 = .008$, R^2 ajustado = $-.002$. $N = 500$. Análisis estadístico realizado en RStudio.

La inteligencia artificial mejora la experiencia de aprendizaje, la autorregulación y la percepción del proceso matemático, pero no garantiza automáticamente un aumento del

rendimiento medido en términos de ganancia académica.

4. Discusión

La inteligencia artificial mejora la experiencia de aprendizaje, la autorregulación y la percepción del proceso matemático, pero no garantiza automáticamente un aumento del rendimiento medido en términos de ganancia académica.

Sin embargo, aunque las competencias digitales mostraron niveles elevados en todas sus dimensiones, el análisis de regresión reveló que estas no predijeron significativamente la ganancia académica. Este hallazgo es congruente con investigaciones que indican que el impacto de la IA en el rendimiento depende del diseño instruccional, la calidad del andamiaje pedagógico y la pertinencia de las tareas evaluativas utilizadas (Zawacki Richter et al., 2019). El hecho de que el rendimiento no se vea directamente influenciado por las percepciones o por el desarrollo de competencias digitales sugiere la necesidad de integrar evaluaciones más sensibles al progreso y actividades más alineadas con los objetivos curriculares, tal como enfatizó Chen et al. (2020) en revisiones sobre inteligencia artificial en educación.

Un aspecto relevante del análisis fue la alta correlación entre las dimensiones de retroalimentación y aprendizaje adaptativo, lo que podría indicar solapamiento conceptual. Esta situación fue reportada previamente en estudios donde la retroalimentación basada en IA se integra de manera inseparable a los mecanismos adaptativos, generando estruc-

turas psicométricas estrechamente vinculadas (Gligorea et al., 2023). Este hallazgo contribuye a explicar en parte la nula capacidad predictiva del modelo de regresión, en la medida en que la multicolinealidad reduce la potencia estadística y dificulta identificar efectos independientes sobre el rendimiento.

Desde la perspectiva ética, los resultados confirmaron una percepción favorable hacia el uso responsable de la IA, coherente con los principios internacionales que abogan por la transparencia, la equidad y la protección de datos (UNESCO, 2021). Esta valoración no solo indica sensibilización respecto al uso de tecnologías educativas, sino que también subraya la necesidad de fortalecer políticas institucionales que garanticen gobernanza de datos y prácticas seguras en entornos digitales.

En conjunto, los hallazgos del estudio aportan evidencia que refuerza el valor de los modelos híbrido-adaptativos para respaldar procesos formativos en nivelación universitaria, aunque también muestran que su impacto sobre el rendimiento académico no es automático ni lineal. La incorporación de IA debe ir acompañada de un diseño instruccional robusto, evaluaciones pertinentes y formación docente continua, elementos mencionados de forma reiterada en la literatura especializada (Son, 2024; Ezzaim et al., 2023).

5. Conclusiones

- Los resultados permiten concluir que la implementación del modelo híbri-

do–adaptativo mediado por IA contribuyó de manera significativa al fortalecimiento de las competencias digitales del estudiantado en el contexto de nivelación en matemáticas. Las percepciones favorables hacia la retroalimentación, el aprendizaje adaptativo y el uso ético de la IA evidencian que los estudiantes reconocen el valor pedagógico y la utilidad de las herramientas digitales en su proceso formativo.

- No obstante, el análisis estadístico mostró que las competencias digitales y las percepciones positivas sobre el uso de IA no predicen directamente la ganancia académica. Este hallazgo sugiere que la mejora del rendimiento depende de factores complementarios como el diseño instruccional, la calidad de las tareas, la alineación con los objetivos curriculares y la sensibilidad de las evaluaciones implementadas. En consecuencia, el uso de IA debe comprenderse como un recurso que potencia el aprendizaje, pero cuya efectividad requiere condiciones pedagógicas y evaluativas adecuadas.
- Se recomienda a las instituciones educativas fortalecer la capacitación docente en estrategias de enseñanza asistidas por IA, desarrollar métricas objetivas de seguimiento del aprendizaje y avanzar hacia diseños experimentales con mayor control. Futuras investigaciones deberían profundizar en la relación entre competencias digitales, autorregulación y rendimiento, incor-

porando análisis longitudinales y ampliando la variedad de indicadores objetivos que permitan estimar con mayor precisión el efecto real de la personalización mediada por IA.

6. Conflicto de intereses

Los autores declaran que no existe conflicto de intereses en relación con el artículo presentado.

7. Declaración de contribución de los autores

Todos autores contribuyeron significativamente en la elaboración del artículo.

8. Costos de financiamiento

La presente investigación fue financiada en su totalidad con fondos propios de los autores.

9. Referencias Bibliográficas

- Cao, W., Nhu Tam Mai, & Guo, W. (2025). Personalized learning and adaptive systems: AI-driven educational innovation and student outcome enhancement. *International Journal of Education and Humanities*, 20(2), 173–182. <https://doi.org/10.54097/tc5k6825>
- Castañeda, L., Esteve, F. & Adell, J. (2018). ¿Por qué es necesario repensar la com-

- petencia docente para el mundo digital? RED. Revista de Educación a Distancia, 56 (6). https://www.um.es/ead/red/56/castaneda_et_al.pdf
- Chassignol, M., Khoroshavin, A., Klimova, A., & Bilyatdinova, A. (2018). Artificial intelligence trends in education: a narrative overview. *Procedia Computer Science*, 136, 16–24. <https://www.sciencedirect.com/science/article/pii/S1877050918315382>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access: Practical Innovations, Open Solutions*, 8, 75264–75278. <https://ieeexplore.ieee.org/document/8974350>
- Ezzaim, A., Dahbi, A., Haidine, A., & Aqqal, A. (2023). AI-based adaptive learning: A systematic mapping of the literature. *Journal of Universal Computer Science*, 29(10), 1161–1197. <https://pdfs.semanticscholar.org/0464/391188371f2ff0d662ffe68e3b823ad0c396.pdf>
- Fernández Morales, D. J., Jiménez Reinoso, N. V., Lagos Ortiz, K., & Tapia Bastidas, T. (2025). Influence of artificial intelligence and its effect on the learning outcomes of first-year high school students. *Conciencia Digital*, 8(1.1), 80-99. <https://doi.org/10.33262/concienciadigital.v8i1.1.3353>
- García Durango, F. T., Peralta Campuzano, A. E., Lara Alejandro, R., & Tobar Farias, G. W. (2025). Impact of the use of artificial intelligence in technical vocational teacher training. *Explorador Digital*, 9(2), 82-108. <https://doi.org/10.33262/exploradordigital.v9i2.3493>
- Gligorea, I., Cioca, M., Oancea, R., Gorski, A.-T., Gorski, H., & Tudorache, P. (2023). Adaptive learning using artificial intelligence in e-learning: a literature review. *Education Sciences*, 13(12), 1216. <https://www.mdpi.com/2227-7102/13/12/1216>
- González Fernández, M. O., Romero-López, M. A., & Sgreccia, N. F. (2025). Marcos normativos para una IA ética y confiable en la educación superior: estado de la cuestión. *RIED-Revista Iberoamericana de Educación a Distancia*, 28(2), 181-208. <https://www.redalyc.org/journal/3314/331481521019/>
- Hariyanto, K., & Maharani, R. (2025). Artificial intelligence in adaptive education: A systematic review of techniques for personalized learning. *Discover Education*, 4(1), 458. <https://doi.org/10.1007/s44217-025-00908-6>
- Koedinger, K. R., Booth, J. L., & Klahr, D. (2013). Instructional complexity and the science to constrain it. *Education Forum*, 342(6161):935-937. <https://learnlab.org/wp-content/uploads/2025/07/Instructional-Complexity.pdf>
- Lubguban, N. S. J., & Bauyot, M. M. (2025). Utilizing artificial intelligence for Education 4.0 and beyond: a systematic review. *Asian Journal of Education and*

- Social Studies, 51(6), 162–183. <https://doi.org/10.9734/ajess/2025/v51i61985>
- Maphalala, M. C., & Ajani, O. A. (2025). Leveraging artificial intelligence as a learning tool in higher education. *Interdisciplinary Journal of Education Research*, 7(1), a01. <https://doi.org/10.38140/ijer-2025.vol7.1.01>
- Martínez Nogales, J. M., Carrasco Pilco, L. F., Guilcapi Mosquera, J. R., & Rodríguez Montalvo, R. P. (2019). Entornos virtuales de aprendizaje y su incidencia en el rendimiento en matemáticas. *Explorador Digital*, 3(3.1), 93-104. <https://doi.org/10.33262/exploradordigital.v3i3.1.867>
- Niño-Rojas, F., Lancheros-Cuesta, D., Jiménez-Valderrama, M. T. P., Mestre, G., & Gómez, S. (2024). Systematic review: trends in intelligent tutoring systems in mathematics teaching and learning. *International Journal of Education in Mathematics, Science, and Technology*, 12(1), 203–229. <https://files.eric.ed.gov/fulltext/EJ1408642.pdf>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2021). Recommendation on the ethics of artificial intelligence. <https://www.unesco.org/en/articles/recommendation-ethics-artificial-intelligence>
- Ramos Galarza, C. (2021). Diseños de investigación experimental. *Revista CienciaAmérica*, 10(1), 1–7. <https://dialnet.unirioja.es/descarga/articulo/7890336.pdf>
- Son, T. (2024). Intelligent tutoring systems in mathematics education: a systematic literature review using the Substitution, Augmentation, Modification, Redefinition Model. *Computers*, 13(10), 270. <https://www.mdpi.com/2073-431X/13/10/270>
- Whittlestone, J., Nyrup, R., Alexandrova, A., & Dihal, K. (2019). Ethical and societal implications of algorithms, data, and artificial intelligence: a roadmap for research. London: Nuffield Foundation. <https://www.nuffieldfoundation.org/sites/default/files/files/Ethical-and-Societal-Implications-of-Data-and-AI-report-Nuffield-Foundat.pdf>
- Yuensook, T., Jantakoon, T., & Limpinan, P. (2024). AI-driven adaptive learning systems in higher education: A systematic review. *Journal of Education and Learning*, 15(2), 117. <https://www.ccsenet.org/journal/index.php/jel/article/view/0/52556>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. Where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1). <https://link.springer.com/article/10.1186/s41239-019-0171-0>