

LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades, Asunción, Paraguay

ISSN en línea: 2789-3855, 2026

Uso guiado de inteligencia artificial generativa en la enseñanza de la programación: un estudio cuasi-experimental sobre resultados de aprendizaje

Guided use of generative Artificial Intelligence in programming education: a quasi-experimental study on learning outcomes

J. Jesús Minero Guardado

jesus.minero@itsn.edu.mx

<https://orcid.org/0009-0007-3741-2673>

TecNM/Instituto Tecnológico Superior de Nochistlán

Nochistlán de Mejía, Zac- México

Elvia Lara García

elvia.lara@itsn.edu.mx

<https://orcid.org/0009-0005-6272-050X>

TecNM/Instituto Tecnológico Superior de Nochistlán

Nochistlán de Mejía, Zac- México

Angélica Avelar Vielmas

angelica.avelar@itsn.edu.mx

<https://orcid.org/0009-0003-0862-5427>

TecNM/Instituto Tecnológico Superior de Nochistlán

Nochistlán de Mejía, Zac- México

DOI: <https://doi.org/10.56712/latam.v7i4.6282>


Redilat
Red de Investigadores Latinoamericanos


LATAM

Revista Latinoamericana de Ciencias Sociales y Humanidades

Artículo recibido: 17 de marzo de 2026.

Aceptado para publicación: 31 de julio de 2026.

Conflictos de Interés: Ninguno que declarar.

VOLUMEN VII

DOI: <https://doi.org/10.56712/latam.v7i4.6282>

Uso guiado de inteligencia artificial generativa en la enseñanza de la programación: un estudio cuasi-experimental sobre resultados de aprendizaje

Guided use of generative Artificial Intelligence in programming education: a quasi-experimental study on learning outcomes

J. Jesús Minero Guardado¹

jesus.minero@itsn.edu.mx

<https://orcid.org/0009-0007-3741-2673>

TecNM/Instituto Tecnológico Superior de Nochistlán
Nochistlán de Mejía, Zac– México

Elvia Lara García

elvia.lara@itsn.edu.mx

<https://orcid.org/0009-0005-6272-050X>

TecNM/Instituto Tecnológico Superior de Nochistlán
Nochistlán de Mejía, Zac– México

Angélica Avelar Vielmas

angelica.avelar@itsn.edu.mx

<https://orcid.org/0009-0003-0862-5427>

TecNM/Instituto Tecnológico Superior de Nochistlán
Nochistlán de Mejía, Zac– México

Artículo recibido: 17 de marzo de 2026. Aceptado para publicación: 31 de julio de 2026.
Conflictos de Interés: Ninguno que declarar.

Resumen

El uso de herramientas de inteligencia artificial (IA) generativa en la enseñanza de la programación ha generado un debate creciente respecto a su impacto en el aprendizaje significativo y el desarrollo del pensamiento computacional. Diversos estudios señalan que la IA puede mejorar la retroalimentación inmediata y el análisis de errores cuando se integra bajo principios pedagógicos adecuados. El presente estudio analiza el efecto del uso guiado de IA generativa sobre el desempeño académico y la progresión del aprendizaje en estudiantes de Ingeniería en Sistemas Computacionales mediante un diseño cuasi-experimental con grupo experimental y grupo control. Para este estudio se consideró al grupo de primer semestre de la carrera de Ingeniería en Sistemas Computacionales en la asignatura de Fundamentos de Programación del Instituto Tecnológico Superior de Nochistlán; se evaluaron a los estudiantes al inicio y al final de la asignatura. Los resultados fueron analizados mediante promedios normalizados (0–100) en tres dimensiones clave: Pensamiento Computacional (PC), Lógica de Programación (LOG) y Sintaxis y Análisis de Código en C++ (PRG). Asimismo, se calculó el Índice de Ganancia Normalizada de Hake (g) como indicador de efectividad del aprendizaje. Complementariamente, los resultados perceptivos evidencian una valoración positiva del uso de la IA como apoyo para la comprensión del código, el análisis crítico y la motivación ante el error, sin que los estudiantes la perciban como un sustituto del docente. Los resultados evidencian que el grupo experimental presentó una ganancia de aprendizaje superior ($g = 0.27$) en comparación con el grupo control ($g = 0.02$), destacando particularmente en la dimensión de Programación y Análisis de Código. Se concluye que el uso guiado de IA puede fortalecer el aprendizaje cuando se integra como

¹ Autor de correspondencia.

herramienta de refuerzo cognitivo orientada a la comprensión y reflexión del código.

Palabras clave: inteligencia artificial generativa, pensamiento computacional, educación en programación, aprendizaje guiado

Abstract

The use of generative artificial intelligence (AI) tools in programming education has sparked a growing debate regarding their impact on meaningful learning and the development of computational thinking. Several studies indicate that AI can enhance immediate feedback and error analysis when integrated under appropriate pedagogical principles. This study analyzes the effect of guided use of generative AI on academic performance and learning progression in Computer Systems Engineering students through a quasi-experimental design with an experimental group and a control group. For this study, a first-semester group from the Computer Systems Engineering program enrolled in the Fundamentals of Programming course at the Instituto Tecnológico Superior de Nochistlán was considered. Students were assessed at the beginning and at the end of the course. The results were analyzed using normalized averages (0–100) across three key dimensions: Computational Thinking (CT), Programming Logic (LOG), and Syntax and Code Analysis in C++ (PRG). Additionally, Hake's Normalized Gain Index (g) was calculated as an indicator of learning effectiveness. Complementarily, perceptual results show a positive evaluation of AI use as support for code comprehension, critical analysis, and motivation when facing errors, without students perceiving it as a substitute for the instructor. The results show that the experimental group achieved a higher learning gain ($g = 0.27$) compared to the control group ($g = 0.02$), with particular improvement in the Programming and Code Analysis dimension. It is concluded that the guided use of AI can strengthen learning when integrated as a cognitive reinforcement tool aimed at code understanding and reflection.

Keywords: generative artificial intelligence, computational thinking, programming education, guided learning

Todo el contenido de LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades, publicado en este sitio está disponibles bajo Licencia Creative Commons.



Cómo citar: Minero Guardado, J. J., Lara García, E., & Avelar Vielmas, A. (2026). Uso guiado de inteligencia artificial generativa en la enseñanza de la programación: un estudio cuasi-experimental sobre resultados de aprendizaje. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades* 7 (4), 985 – 997. <https://doi.org/10.56712/latam.v7i4.6282>

INTRODUCCIÓN

La formación de ingenieros en sistemas computacionales enfrenta uno de sus mayores obstáculos en la enseñanza de la programación, principalmente por el desgaste intelectual y la saturación mental que conllevan el diseño de algoritmos, el dominio de la sintaxis y la interpretación del sentido del código. Actualmente el marco educativo internacional demanda la adquisición de nuevas habilidades para asimilar conocimientos y trabajar en equipo dentro de un ecosistema tecnológico en permanente transformación (Voogt et al., 2013). Bajo este enfoque, una competencia fundamental es el pensamiento computacional, este es esencial para solucionar problemas complejos sirviéndose de la abstracción y la segmentación de problemas en entornos virtuales (Grover & Pea, 2018; Shute et al., 2017).

En los últimos años, la llegada de los modelos de inteligencia artificial generativa ha modificado drásticamente las formas de enseñanza, sobre todo en las ciencias de la computación. La literatura científica actual destaca sus virtudes para explicar el funcionamiento de los programas línea por línea y servir de soporte en la corrección de errores; sin embargo, también previene sobre las secuelas de la dependencia tecnológica y la disminución de la capacidad de cuestionamiento si se prescinde de un acompañamiento educativo estructurado (Becker et al., 2023; Prather et al., 2023).

Tomando como base la corriente constructivista, la cual sostiene que el saber se construye mediante la práctica y la reestructuración de los esquemas mentales internos a través de la vivencia directa (Piaget, 1950), la utilidad didáctica de la IA reside en su potencial para fungir como una herramienta de apoyo al pensamiento o mindtool. Bajo este fundamento, la tecnología va más allá de proporcionar soluciones inmediatas, pues estimula la autoevaluación y los procesos metacognitivos del estudiante (Jonassen, 1996). Esta postura guarda una estrecha relación con las metodologías de aprendizaje activo-constructivo-interactivo, las cuales incentivan la apropiación del conocimiento mediante una interacción crítica y deliberativa con las plataformas digitales (Chi, 2009). Por lo tanto, esta investigación se plantea como propósito medir el efecto del uso guiado de Inteligencia Artificial generativa en el aprendizaje de programación, vinculando variables de rendimiento escolar y la evolución del aprendizaje en diferentes áreas del conocimiento en estudiantes de nivel superior en la carrera de Ingeniería en Sistemas Computacionales.

METODOLOGÍA

Se adoptó un diseño cuasi-experimental con grupo control y un grupo experimental, este diseño se eligió para aprovechar los datos en un contexto educativo real, así se mantuvo condiciones similares para ambos grupos (Baker & Siemens, 2021). Los grupos pertenecían al mismo programa académico y cursaban la asignatura bajo condiciones institucionales similares para minimizar variables intervinientes.

Para determinar la muestra se tomó al grupo de primer semestre de la carrera de Ingeniería en Sistemas Computacionales con la asignatura de Fundamentos de Programación en el Instituto Tecnológico Superior de Nochistlán. En la muestra se consideraron a los estudiantes que iniciaron y concluyeron el semestre, con el propósito de contar con datos completos para el análisis de la investigación.

Los instrumentos utilizados para la recolección de datos fueron evaluaciones para medir el desempeño de estudiantes y cuestionarios para medir la percepción.

Evaluación de Desempeño

Se midieron a los estudiantes en dos momentos, uno al inicio del curso (pre-test) y otro al final (post-test) para medir su avance, para revisar estos resultados se elaboraron rúbricas adaptativas como las

propuso Ithantola & Edwards (2021). La evaluación se centró en tres dimensiones: Pensamiento Computacional (PC), Lógica de Programación (LOG), y Sintaxis y Análisis de Código en C++ (PRG). Según Paiva et al. (2022), esta estructura se alinea con tendencias contemporáneas en la computación. Estas dimensiones se utilizaron de la siguiente manera:

- El PC analiza cómo piensan los estudiantes al resolver un problema.
- LOG, se revisó para ver cómo el estudiante ordena pasos para crear un programa.
- PRG, para ver como escriben y entienden código en el lenguaje C++, que fue el lenguaje de programación seleccionado para el curso.

Cuestionario de Percepción

Los estudiantes que utilizaron la inteligencia artificial (grupo experimental) fueron cuestionados sobre lo que pensaban y sentían al utilizar la IA al momento de resolver problemas de programación presentados en la materia, el cuestionario utilizó preguntas tipo "Linker" con escala de números de 0 a 5 para medir con precisión qué tanto les ayudó.

Este cuestionario mide lo siguiente:

- Comprensión de código para ver si les ayudo a entender cómo funcionan los programas.
- Análisis crítico, donde se determinaba si los estudiantes pensaban por sí mismos y revisaban errores de la IA, en lugar de solo copiar y pegar.
- Motivación, aquí se cuestionó si la IA ayudó a que la clase fuera más atractiva.

IA como mediador, si funciona como tutor o puente en el aprendizaje autorregulado. (Deci & Ryan, 1985; Pintrich et al., 1991)

El proceso duró 14 semanas (un semestre escolar). Durante este tiempo ambos grupos, el experimental (utilizan IA) y al grupo control (no utilizan IA) se les daban retos de programación a través de ejercicios planteados en clase y ambos deberían resolverlos.

Al grupo experimental se le permitió utilizar la IA, pero no solo como herramienta de andamiaje cognitivo es decir como soporte para pedirle que explicara paso a paso partes de código difíciles para ellos, ayuda sobre mensajes de error que les daba el compilador y cómo podrían corregirlo y como comparación de códigos para ver el camino más corto o eficiente para resolución del problema (Jonassen, 1996).

El grupo control hizo los mismos ejercicios, pero siguiendo su clase normal junto a su docente, si tenían dudas podían consultar libros o a su docente.

Para que fuera más sencillo de analizar y comprender los datos obtenidos de las evaluaciones de desempeño se normalizaron a una escala de 0 a 100, en lugar de solo restar la nota del examen final menos el inicial (lo que no puede ser justo), se aplicó la fórmula propuesta por el científico Hake (1998). Esta fórmula mide qué porcentaje de lo que faltaba por aprender el estudiante logró recuperar. Este enfoque estadístico elimina el "efecto techo" permitiendo comparar grupos con diferentes niveles de desempeño inicial de manera más equilibrada y midiendo realmente la progresión de los estudiantes. La interpretación de los resultados se basó en los umbrales establecidos por Hake: ganancia baja ($g < 0.3$), media ($0.3 \leq g < 0.7$) y alta ($g \geq 0.7$).

DESARROLLO

Estudios recientes destacan que la IA mejora la personalización del aprendizaje y ofrece retroalimentación inmediata (Baker & Siemens, 2021), especialmente en programación, donde herramientas como ChatGPT ayudan a depurar código y explicar conceptos en tiempo real (Ma et al.,

2024). Sin embargo, su uso excesivo puede reducir la calidad del código y limitar la colaboración entre pares (Groothuijsen et al., 2024), lo que sugiere la necesidad de un equilibrio pedagógico.

La integración de generadores de código basados en IA ha demostrado potenciar habilidades de descomposición y abstracción (Yilmaz & Yilmaz, 2022), pero también plantea riesgos como la comprensión superficial de conceptos cuando los estudiantes dependen de soluciones automáticas (Takerngsaksiri et al., 2023). Esto refuerza hallazgos previos sobre la reducción de la carga cognitiva (García & Rodríguez, 2021), pero advierte sobre la pérdida de competencias en etapas avanzadas (Rahman & Watanobe, 2024).

El uso de IA generativa incrementa la motivación intrínseca y la autoeficacia en programación, según Yilmaz y Yilmaz (2022), al proporcionar respuestas rápidas y reducir la frustración. No obstante, Boguslawski et al. (2024) enfatizan que estas herramientas no sustituyen el apoyo docente, crucial para mantener la motivación en proyectos complejos.

Mientras Gómez y Pérez (2021) resaltan el potencial de la IA para fomentar colaboración, estudios recientes contradicen esto: Sun et al. (2024) observaron que ChatGPT reduce interacciones entre estudiantes, y Groothuijsen et al. (2024) notaron un declive en la programación en parejas. Esto indica que el diseño de las actividades (ej. roles definidos) es clave para mitigar efectos negativos.

Aunque se ha estudiado el impacto a corto plazo (ej. mejora en calificaciones; Yilmaz & Yilmaz, 2022), persiste una laguna sobre efectos a largo plazo (Rahman & Watanobe, 2024). Además, faltan métricas estandarizadas para evaluar cómo la IA afecta la calidad del código (Groothuijsen et al., 2024) y la transferencia de habilidades a entornos sin IA (Takerngsaksiri et al., 2023).

Esta investigación se basa en varias teorías educativas:

Aprendizaje constructivista: Sostiene que el conocimiento se construye activamente mediante la interacción con el entorno (Piaget, 1970).

Aprendizaje basado en tecnología: Propone que las herramientas digitales pueden optimizar los procesos de enseñanza y aprendizaje.

Aprendizaje autorregulado: Sugiere que el uso de IA puede mejorar la metacognición y la autonomía en el aprendizaje de los estudiantes (Rahman & Watanobe, 2024).

Hsu y colaboradores (2023) definen el pensamiento computacional (PC) como un conjunto de habilidades cognitivas —descomposición, abstracción, reconocimiento de patrones y diseño algorítmico— que permiten resolver problemas complejos mediante principios fundamentales de la informática. Los autores destacan que, en la era de la IA, el PC no solo facilita la comprensión de la programación, sino que también actúa como un mediador crítico para evaluar cómo los estudiantes integran, depuran y adaptan el código generado por herramientas como ChatGPT o ChatGPT en su aprendizaje (Hsu et al., 2023). El PC será la base teórica para medir el rendimiento académico en esta investigación.

La teoría general sobre la motivación educativa tiene raíces en diversas corrientes psicológicas y educativas. No hay un solo origen, sino que surge de varias teorías clave desarrolladas por diferentes investigadores a lo largo del tiempo.

La motivación es el resultado de refuerzos externos, como premios o castigos, que aumentan o disminuyen la probabilidad de una conducta (Skinner, 1953).

La motivación académica es el conjunto de procesos psicológicos que activan, dirigen y mantienen el esfuerzo de un estudiante en tareas de aprendizaje. Se relaciona con el interés, la persistencia y el

rendimiento escolar. Definen la motivación académica como "el proceso mediante el cual se inicia y mantiene el comportamiento orientado al aprendizaje, influenciado por creencias, metas y emociones" (Schunk, Pintrich & Meece, 2014).

Deci y Ryan (1985) Proponen la Teoría de la Autodeterminación, donde la motivación académica puede ser intrínseca (cuando el estudiante aprende por placer o interés) o extrínseca (cuando aprende por recompensas externas como calificaciones o reconocimiento).

Existen diversas herramientas de evaluación de la motivación educativa que permiten medir los factores que influyen en el aprendizaje de los estudiantes. Estas herramientas se basan en diferentes enfoques y teorías psicológicas de la motivación, y se utilizan para analizar la motivación de manera individual o grupal. Por ejemplo, la Escala de Motivación Académica (AMS) de Vallerand mide la motivación intrínseca, extrínseca y la desmotivación en contextos educativos. Otra herramienta es el Motivated Strategies for Learning Questionnaire (MSLQ) de Pintrich et al. (1991), que evalúa tanto la motivación como las estrategias de aprendizaje utilizadas por los estudiantes. Estas herramientas se fundamentan en teorías como la Teoría de la Autodeterminación de Deci y Ryan, y la Teoría de la Atribución de Weiner, proporcionando un marco integral para comprender y evaluar la motivación académica.

La herramienta que se utilizará en esta investigación es el cuestionario de Motivación y Estrategias de aprendizaje (MSLQ) este fue desarrollado por Pintrich et al. (1991), el MSLQ se enfoca en las estrategias de aprendizaje y la motivación. Evalúa tanto la motivación intrínseca como las estrategias de aprendizaje empleadas por los estudiantes, proporcionando un perfil más detallado de cómo los estudiantes abordan su aprendizaje. Se utiliza comúnmente en universidades y otros entornos educativos superiores, ideal para evaluar el impacto de intervenciones pedagógicas en la motivación y rendimiento académico.

Rubin et al. (2022) en su estudio, mencionan la necesidad de que las rúbricas en programación cubran varias dimensiones clave como la correctitud sintáctica, eficiencia algorítmica, estilo de código y documentación. Además, destacan que el uso de rúbricas detalladas ayuda a reducir la subjetividad y mejora la autorregulación del aprendizaje en estudiantes. Además, Ithantola & Edwards (2021) proponen el uso de rúbricas que se ajusten al nivel de habilidad del estudiante (principiante o avanzado), con el objetivo de evitar sesgos en la evaluación. En esta investigación se utilizarán las rúbricas para medir las habilidades de programación de los estudiantes.

RESULTADOS

Resultados Generales por Grupo

El grupo experimental evidenció una progresión de aprendizaje considerablemente mayor. Aunque la ganancia obtenida ($g = 0.27$) se clasifica como baja según los umbrales estrictos de Hake (Hake, 1998), representa un incremento sustancial frente a la mejora casi nula del grupo control ($g = 0.02$), destacando el impacto positivo de la intervención considerando incluso la complejidad de la asignatura, la cual suele representar dificultades para estudiantes de primer semestre debido a la necesidad de desarrollar habilidades de lógica, abstracción y resolución de problemas, además que dentro de la institución se reciben estudiantes sin el perfil solicitado para la carrera. En este contexto, el uso de herramientas de IA parece haber funcionado como un apoyo para facilitar la comprensión de conceptos y reducir algunas barreras iniciales de aprendizaje. La Tabla 1 muestra los datos obtenidos de ambos grupos, además se incluyen los resultados por dimensiones de aprendizaje.

Tabla 1

Resultados generales por grupo

Grupo	Prom. Pre	Prom. Post	Ganancia Hake (g)	PC (Post)	LOG (Post)	PRG (Post)
IA (Experimental)	47.40	60.20	0.27	57.14	60.71	60.71
Sin IA (Control)	52.27	52.98	0.02	54.17	66.67	50.00

Fuente: elaboración propia.

Resultados por Dimensión de Aprendizaje

El análisis por dimensiones permitió identificar en qué áreas específicas se observaron mayores diferencias entre los grupos.

En la dimensión de Pensamiento Computacional, el grupo experimental obtuvo un resultado superior al grupo control. Este resultado puede relacionarse debido a que con el uso de herramientas de IA se favorecen procesos de descomposición de problemas, identificación de patrones y abstracción, habilidades fundamentales en esta dimensión (Grover & Pea, 2018; Shute et al., 2017).

Durante los retos propuestos de programación, los estudiantes podían recibir retroalimentación inmediata y ejemplos alternativos para resolver ejercicios, lo que facilitó la comprensión de la estructura lógica de los problemas. Además, la interacción constante con asistentes inteligentes promovió una mayor exploración de soluciones y estrategias de resolución.

En la dimensión de Lógica de Programación se observaron diferencias moderadas entre ambos grupos. Aunque el grupo control obtuvo resultados competitivos, el grupo experimental mostró un desempeño más equilibrado y consistente.

Estos resultados sugieren que el desarrollo de la lógica de programación continúa dependiendo en gran medida de la práctica individual, la repetición de ejercicios y el razonamiento personal del estudiante. La IA puede funcionar como apoyo para aclarar dudas y mostrar ejemplos, pero no reemplaza el proceso cognitivo necesario para construir estructuras lógicas sólidas.

Además, algunos estudiantes utilizaron la IA principalmente para validar respuestas o verificar errores, lo cual pudo contribuir al fortalecimiento gradual de sus habilidades lógicas.

La dimensión de Programación y Análisis fue donde se observó el mayor impacto del uso de IA. El grupo experimental obtuvo resultados superiores respecto al grupo control, lo cual coincide con investigaciones recientes que destacan la utilidad de los asistentes inteligentes para apoyar procesos de depuración, generación de código y comprensión de estructuras de programación (Finnie-Ansley et al., 2022; MacNeil et al., 2022; Wermelinger, 2023).

Los estudiantes que utilizaron IA lograron identificar errores con mayor rapidez y comprender mejor la funcionalidad de fragmentos de código por la interacción y resolución de dudas. Asimismo, las herramientas inteligentes permitieron obtener explicaciones inmediatas sobre sintaxis y lógica de programación, favoreciendo un aprendizaje más dinámico y autónomo.

Sin embargo, también se identificó dentro de los retos que algunos estudiantes tendían a depender excesivamente de las respuestas generadas automáticamente, lo que evidencia la necesidad de establecer estrategias pedagógicas que promuevan un uso crítico y reflexivo de la IA dentro del aula.

En términos generales, los resultados muestran que la integración de herramientas de inteligencia artificial puede contribuir positivamente al aprendizaje de programación, especialmente en tareas relacionadas con análisis de código y resolución de problemas. Sin embargo, el impacto varía según la dimensión evaluada, siendo más significativo en habilidades prácticas que en competencias relacionadas con razonamiento lógico profundo y es aquí donde la intervención del docente debe continuar para irse asegurando de ese razonamiento.

Análisis Individual de Aprendizaje

El análisis individual de los estudiantes permitió identificar diferencias importantes en el nivel de aprovechamiento de la intervención basada en inteligencia artificial. Aunque el promedio general del grupo experimental mostró una mejora moderada, algunos estudiantes alcanzaron ganancias de aprendizaje significativamente altas, con valores de ganancia normalizada superiores a ($g > 0.6$). Esto indica que ciertos participantes lograron aprovechar de manera sobresaliente las herramientas de IA durante el proceso de aprendizaje.

Estos resultados sugieren que el impacto de la IA no fue uniforme para todos los estudiantes, sino que depende de factores individuales como la motivación, la autonomía, los conocimientos previos y la forma en que cada estudiante interactúa con las herramientas tecnológicas.

Asimismo, se observó durante las sesiones que los estudiantes con mayor participación y práctica constante tendieron a obtener mejores ganancias de aprendizaje. Esto refuerza la idea de que la IA funciona de manera más efectiva cuando se integra como una herramienta de acompañamiento al proceso de razonamiento y no como un sustituto del aprendizaje activo.

Por otro lado, algunos estudiantes presentaron mejoras menores o incluso resultados similares al pretest inicial. Esto podría relacionarse con un uso limitado de las herramientas, dificultades de adaptación a la metodología o dependencia excesiva de las respuestas generadas automáticamente, sin un proceso adecuado de análisis y comprensión.

La variabilidad observada coincide con investigaciones recientes que señalan que las herramientas generativas de IA pueden producir efectos distintos según las características individuales y las estrategias de uso implementadas por los estudiantes (Becker et al., 2023; Prather et al., 2023). En este sentido, los resultados evidencian que la efectividad de la IA en educación no depende únicamente de la tecnología utilizada, sino también de las habilidades de autorregulación y pensamiento crítico desarrolladas por los estudiantes.

En términos generales, el análisis individual muestra que la integración de IA puede potenciar significativamente el aprendizaje en algunos estudiantes, especialmente en aquellos que mantienen una participación activa y reflexiva durante el proceso formativo. Sin embargo, también pone de manifiesto la necesidad de acompañamiento docente para orientar el uso adecuado de estas herramientas y evitar prácticas de dependencia tecnológica.

Resultados Cualitativos y Perceptivos

Además de los resultados cuantitativos, la fase inicial del estudio incluyó evidencia cualitativa derivada de observaciones de aula y percepciones estudiantiles documentadas durante el desarrollo de las actividades prácticas. La Tabla 2 muestra esta percepción.

Tabla 2

Percepción de la inteligencia artificial como apoyo educativo en el grupo experimental

Dimensión de la competencia	Media (escala 0–5)	Nivel de percepción
Intención de comprensión del código	4.83	Muy alta
Análisis crítico de la solución	4.50	Muy alta
Incentivo para resolver retos difíciles	4.00	Alta
Motivación ante errores de ejecución	3.50	Media-alta
Valoración de la IA como apoyo (no sustituto)	3.50	Media-alta

Fuente: elaboración propia.

Los hallazgos cualitativos indican que los estudiantes del grupo experimental valoraron positivamente el uso de la IA como apoyo para:

- La comprensión del código, especialmente durante la interpretación de soluciones alternativas;
- El análisis crítico de errores, permitiendo identificar causas y comparar estrategias de corrección;
- El refinamiento progresivo de soluciones, mediante iteraciones guiadas;
- El incremento de la motivación ante el error, reduciendo la frustración asociada a fallos sintácticos o lógicos.

De manera consistente, los participantes no percibieron la IA como sustituto del docente, sino como un recurso complementario que facilitó la discusión y validación de soluciones dentro del aula. Este comportamiento demuestra que la herramienta se integró bajo un enfoque de aprendizaje activo y constructivo (Chi, 2009), operando como un puente para el pensamiento y no como una herramienta que soluciona las tareas de forma automática. Esta percepción de los estudiantes refuerza como la IA es solo una herramienta de refuerzo cognitivo, que estimula la propia reflexión y la autonomía al estudiar (Jonassen, 1996).

DISCUSIÓN

Los resultados demuestran que el beneficio de emplear de forma guiada la IA favorece principalmente en la evolución del aprendizaje y en el afianzamiento de destrezas cognitivas ligadas a la revisión de código. El aumento en el área de sintaxis y análisis (PRG) revela que la IA funciona como un soporte cuando el alumno depura y asimila la semántica de sus programas. Sin embargo, el progreso moderado en la lógica algorítmica (LOG) comprueba que este tipo de tecnología no reemplaza los procesos de razonamiento deductivo del estudiante, sino que actúa como un complemento didáctico siempre que el docente medie ese proceso (Holmes et al., 2019; Selwyn, 2019). Los principios éticos de la Inteligencia Artificial Educativa indican que estas herramientas deben programarse para asistir y complementar, pero no para mermar la independencia del alumno (Luckin et al., 2017). Por lo tanto, los resultados logrados se deben al diseño de la estrategia pedagógica y no a los beneficios tácitos del software de forma aislada.

De acuerdo a Deci y Ryan (1985) en su teoría de la autodeterminación, disponer de respuestas y explicaciones inmediatas incrementa el sentimiento de autoeficacia y el interés propio por aprender. Así mismo, conseguir que el alumno experimente menos frustración frente a las fallas lógicas concuerda con las investigaciones previas sobre plataformas adaptativas y tutores inteligentes (Woolf, 2010).

La opinión de los estudiantes del grupo experimental complementa este análisis. Los promedios elevados en indicadores como el interés por comprender los algoritmos ($M = 4.83$) y el análisis crítico de las soluciones ($M = 4.50$) comprueban que el estudiante no adoptó la IA como un medio de resolución automática, sino como una guía para entender y valorar sus propios códigos. Esta actitud se ajusta al modelo de Chi (2009) aprendizaje activo-constructivo, el cual sostiene que la interacción con medios digitales externos enriquece la asimilación del conocimiento. De igual manera, concebir a la IA como un soporte instruccional ajeno al rol docente ($M = 3.50$) es coherente con las perspectivas teóricas de Holmes y Selwyn (2019) que previenen sobre los peligros de incorporar tecnologías avanzadas sin un sentido crítico. Bajo este panorama, la herramienta actúa como un impulsor del pensamiento, vinculándose al concepto de mindtools (Jonassen, 1996), y no como un tutor autónomo. En la resolución y entendimiento de errores que es un plano más afectivo, los rangos medios-altos sugieren que el uso de la IA atenuó la frustración frente al error, incentivando la perseverancia en la resolución de problemas complejos.

CONCLUSIÓN

El estudio demuestra que el uso guiado de inteligencia artificial generativa puede favorecer el progreso del aprendizaje en programación cuando se integra a través de estrategias pedagógicas bien estructuradas.

Los resultados por área muestran que:

La IA favorece especialmente el análisis de código y la comprensión de la sintaxis.

La lógica de programación mantiene dependencia en gran medida de la práctica y el esfuerzo individual.

La ganancia global de aprendizaje del grupo experimental logró un avance significativo mayor al grupo control.

La percepción positiva de los estudiantes respecto al uso de la IA como recurso para la interpretación del código, fortalecer el análisis crítico y gestionar errores sugiere que estas herramientas no fomentan automáticamente la dependencia, siempre y cuando existan lineamientos claros que promuevan la reflexión y el aprendizaje activo.

Sin embargo, el efecto moderado identificado en las evaluaciones globales indica que la integración de la inteligencia artificial no garantiza por sí misma mejoras integrales en el desempeño académico, lo que resalta la importancia del diseño instruccional, la intervención docente y la selección de actividades que favorezcan procesos cognitivos de mayor complejidad.

Como limitación, este estudio se encuentra en una fase exploratoria con un tamaño de muestra reducido y un contexto institucional específico. Por ello, futuras investigaciones deberán considerar muestras más amplias, incorporar análisis longitudinales y explorar relaciones entre el uso de IA, el nivel inicial de desempeño y la autorregulación del aprendizaje. En conjunto, los hallazgos aportan evidencia relevante para promover el uso responsable, ético y pedagógicamente fundamentado de la inteligencia artificial en la educación en ingeniería.

Por lo tanto, se concluye que la inteligencia artificial debe asumirse como herramienta de apoyo cognitivo complementario al proceso de enseñanza-aprendizaje y no como sustituto del proceso formativo, en concordancia con recomendaciones internacionales sobre adopción responsable en el ámbito educativo (Luckin et al., 2017; OECD, 2021).

REFERENCIAS

- Baker, R. S., & Siemens, G. (2021). Educational Data Mining and Learning Analytics. Cambridge University Press.
- Becker, B. A., Denny, P., Luxton-Reilly, A., & Hanks, B. (2023a). Computing Education in the Era of Generative AI. *Communications of the ACM*, 66(10), 24–26.
- Becker, B. A., Denny, P., Luxton-Reilly, A., & Hanks, B. (2023b). Generative AI in computing education: Understanding impacts on learning. En *Proceedings of the 2023 ACM Conference on International Computing Education Research (ICER 2023)*.
- Boguslawski, S., et al. (2024). [Título completo faltante]. [Revista], [volumen], [páginas]. <https://doi.org/xxxx>
- Chi, M. T. H. (2009). Active–constructive–interactive: A conceptual framework. *Topics in Cognitive Science*, 1(1), 73–105.
- Deci, E. L., & Ryan, R. M. (1985). *Intrinsic Motivation and Self-Determination in Human Behavior*. Springer.
- Finnie-Ansley, J., Denny, P., Becker, B. A., Luxton-Reilly, A., & Prather, J. (2022). The effect of AI-based code generation tools on programming learning. En *Proceedings of the 53rd ACM Technical Symposium on Computer Science Education (SIGCSE 2022)*.
- García, M., & Rodríguez, L. (2021). AI technologies for education: Recent research & future directions. *ScienceDirect*.
- Gómez, F., & Pérez, C. (2021). Collaborative learning and AI in education: Enhancing teamwork and critical thinking through code generators. Springer.
- Groothuijsen, S. E. A., et al. (2024). [AI chatbots in programming education...]. *Computers & Education: AI*, 5, 100290. <https://doi.org/10.1016/j.caeai.2024.100290>
- Grover, S., & Pea, R. (2018). Computational thinking: A competency whose time has come. *Computer Science Education*, 28(1), 19–38.
- Hake, R. R. (1998). Interactive-engagement versus traditional methods: A six-thousand-student survey of mechanics test data for introductory physics courses. *American Journal of Physics*, 66(1), 64–74. <https://doi.org/10.1119/1.18809>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education*. Center for Curriculum Redesign.
- Hsu, T.-C., Abelson, H., & Van Brummelen, J. (2023). Computational thinking and artificial intelligence: Synergies and challenges for 21st-century education. *Computers & Education: Artificial Intelligence*, 4, 100140. <https://doi.org/10.1016/j.caeai.2023.100140>
- Ihantola, P., & Edwards, S. H. (2021). Adaptive rubrics for programming assessment. *Computer Science Education*, 31(3), 320–339.
- Jonassen, D. H. (1996). *Computers in the Classroom: Mindtools for Critical Thinking*. Prentice Hall.
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence Unleashed: An Argument for AI in Education*. Pearson.

Luckin, R., et al. (2017). Ethics and AIED: Who cares? *International Journal of Artificial Intelligence in Education*, 27, 1–23.

Ma, L., et al. (2024). [Título completo faltante]. [Revista], [volumen], [páginas]. <https://doi.org/xxxx>

MacNeil, S., et al. (2022). Experiences from using code explanations generated by large language models. En *Proceedings of the 53rd ACM Technical Symposium on Computer Science Education (SIGCSE 2022)*.

OECD. (2021). *Artificial Intelligence in Education: Challenges and Opportunities*. OECD Publishing.

Paiva, J. C., Leal, J. P., & Queirós, R. (2022). Automated assessment in computer science education: A systematic review. *ACM Computing Surveys*, 54(11s).

Piaget, J. (1950). *The Psychology of Intelligence*. Routledge.

Piaget, J. (1970). *La epistemología de las ciencias de la educación*. Siglo XXI Editores.

Pintrich, P. R., Smith, D. A. F., Garcia, T., & McKeachie, W. J. (1991). *A Manual for the Use of the Motivated Strategies for Learning Questionnaire*. University of Michigan.

Prather, J., et al. (2023). The robots are coming: Exploring the implications of OpenAI Codex. En *Proceedings of the 54th ACM Technical Symposium on Computer Science Education (SIGCSE 2023)*.

Rahman, M. M., & Watanobe, Y. (2024). [Título completo faltante]. [Revista], [volumen], [páginas]. <https://doi.org/xxxx>

Rubin, M. J., Ihtantola, P., & Edwards, S. H. (2022). Rubric-based assessment in introductory programming: A longitudinal study of consistency and fairness. *ACM Transactions on Computing Education*, 22(3), 1-25. <https://doi.org/10.1145/3513140>

Schunk, D. H., Pintrich, P. R., & Meece, J. L. (2014). *Motivation in education: Theory, research, and applications*. Pearson Higher Ed.

Selwyn, N. (2019). *Should Robots Replace Teachers?* Polity Press.

Shute, V. J., Sun, C., & Asbell-Clarke, J. (2017). Demystifying computational thinking. *Educational Research Review*, 22, 142–158.

Skinner, B. F. (1953). *Science and Human Behavior*. New York: Macmillan.

Sun, Y., et al. (2024). [Título completo faltante]. [Revista], [volumen], [páginas]. <https://doi.org/xxxx>

Sweller, J., Ayres, P., & Kalyuga, S. (2011). Altering element interactivity and intrinsic cognitive load. En *Cognitive Load Theory*. Springer.

Takerngsaksiri, W., et al. (2023). [Students' perspective on AI code completion...]. *arXiv*. <https://doi.org/10.48550/arXiv.2311.00177>

Voogt, J., Erstad, O., Dede, C., & Mishra, P. (2013). Challenges to learning and schooling in the digital networked world. *Journal of Computer Assisted Learning*, 29(5), 403–413.

Yilmaz, R., & Yilmaz, F. G. K. (2022). [The effect of generative AI...]. *Computers & Education: AI*, 3, 100171. <https://doi.org/10.1016/j.caeai.2022.100171>

Wermelinger, M. (2023). Using GitHub Copilot to Solve Simple Programming Problems. En Proceedings of the 54th ACM Technical Symposium on Computer Science Education (SIGCSE 2023).

Woolf, B. P. (2010). Building Intelligent Interactive Tutors. Morgan Kaufmann.

Todo el contenido de LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades, publicados en este sitio está disponibles bajo Licencia [Creative Commons](#) 