

Didactic strategy with artificial intelligence for learning Newtonian mechanics
Estrategia didáctica con inteligencia artificial para el aprendizaje de la mecánica Newtoniana

Autores:

Lloor-Solórzano, Edgar Santiago
UNIVERSIDAD TÉCNICA DE MANABÍ
Maestrante de Pedagogía de las Ciencias Experimentales mención Matemáticas y Física
Guayaquil – Ecuador.

 elloor3842@utm.edu.ec
 <https://orcid.org/0009-0000-2891-8444>

Pavón-Brito, Christian Antonio
UNIVERSIDAD DE GUAYAQUIL
Ing. Mecánico
Máster en Educación de la Física.
Docente de Matemáticas y Física
Guayaquil – Ecuador.

 christian.pavonb@ug.edu.ec
 <https://orcid.org/0000-0002-8913-1546>

Olarte-Sancán, Yandry José
UNIVERSIDAD TÉCNICA DE MANABÍ
Ing. En Sistemas Informáticos
Master en Tecnologías de la información
Docente de Matemáticas y Física
Portoviejo – Ecuador.

 yandry.olarte@utm.edu.ec
 <https://orcid.org/0000-0002-9581-5557>

Fechas de recepción: 06-ABR-2025 aceptación: 06-MAY-2025 publicación: 30-JUN-2025

 <https://orcid.org/0000-0002-8695-5005>
<http://mqrinvestigar.com/>



Resumen

La comprensión conceptual de la mecánica newtoniana continúa siendo un reto en la educación científica, especialmente en contextos donde persisten metodologías tradicionales y concepciones alternativas. Este estudio tuvo como objetivo evaluar el impacto de una estrategia didáctica basada en la instrucción entre pares, mediada por inteligencia artificial, sobre el aprendizaje de la mecánica newtoniana. Se adoptó un enfoque cuantitativo con un diseño cuasiexperimental de tipo pretest-postest con grupos no equivalentes. La muestra estuvo compuesta por 55 estudiantes universitarios de la carrera de Pedagogía de las Ciencias Experimentales de la Universidad de Guayaquil. El grupo experimental utilizó ChatGPT como par académico durante las sesiones, mientras que el grupo de control aplicó la instrucción entre pares tradicional. El aprendizaje conceptual fue medido mediante el Force and Motion Conceptual Evaluation (FMCE). Los resultados muestran mejoras significativas en ambos grupos ($p < 0,001$), con ganancias normalizadas superiores en el grupo experimental ($g = 0,53$ frente a $g = 0,42$) y un tamaño del efecto intergrupar moderado-alto ($d = 0,666$). Además, se observaron tamaños del efecto muy grandes dentro de cada grupo ($d > 2,4$). Se concluye que la inteligencia artificial puede actuar como mediador pedagógico eficaz, favoreciendo el cambio conceptual y complementando estrategias activas de aprendizaje. Estos hallazgos respaldan la integración de tecnologías emergentes en la enseñanza de la física y abren nuevas líneas de investigación sobre el uso de agentes conversacionales en contextos educativos.

Palabras clave: mecánica newtoniana; inteligencia artificial; instrucción entre pares, aprendizaje conceptual; cambio conceptual



Abstract

The conceptual understanding of Newtonian mechanics remains a persistent challenge in science education, particularly in contexts where traditional methods and alternative conceptions prevail. This study aimed to evaluate the impact of a peer instruction strategy mediated by artificial intelligence on the learning of Newtonian mechanics. A quantitative approach was adopted through a quasi-experimental pretest-posttest design with nonequivalent groups. The sample consisted of 55 university students from the Pedagogy of Experimental Sciences program at the University of Guayaquil. The experimental group used ChatGPT as an academic peer during instructional sessions, while the control group applied traditional peer instruction. Conceptual understanding was assessed using the Force and Motion Conceptual Evaluation (FMCE). The results revealed significant improvements in both groups ($p < 0.001$), with higher normalized gains in the experimental group ($g = 0.53$ vs. $g = 0.42$) and a moderate-to-large intergroup effect size ($d = 0.666$). Additionally, very large effect sizes were observed within each group ($d > 2.4$). It is concluded that artificial intelligence can serve as an effective pedagogical mediator, promoting conceptual change and enhancing active learning strategies. These findings support the integration of emerging technologies in physics education and suggest new research pathways regarding the use of conversational agents in educational contexts.

Keywords: Newtonian mechanics; artificial intelligence; peer instruction; conceptual learning, conceptual change

Introducción

La enseñanza de la mecánica newtoniana representa un desafío persistente en la educación científica. Aunque constituye uno de los pilares fundamentales de la física clásica, los estudiantes suelen experimentar dificultades para comprender sus conceptos esenciales, lo que repercute negativamente tanto en su desempeño académico como en su actitud hacia la disciplina (Rosales & Sulaiman, 2020). A nivel internacional, se ha documentado ampliamente que estas dificultades están asociadas a la permanencia de modelos mentales erróneos, que obstaculizan el tránsito hacia estructuras de conocimiento alineadas con la ciencia formal (Robertson et al., 2023).

Estas dificultades también se reproducen en América Latina, donde diversos estudios evidencian una persistencia de concepciones alternativas incluso después de procesos formales de instrucción. Factores como la limitada disponibilidad de recursos educativos, la escasa incorporación de metodologías activas y la descontextualización de los contenidos han sido identificados como limitantes relevantes (Artamónova et al., 2017). En este contexto, la necesidad de implementar enfoques más interactivos y significativos se vuelve aún más apremiante (Lino et al 2023).

En el caso ecuatoriano, el problema adquiere una dimensión particular: la física se encuentra entre las asignaturas con mayores índices de reprobación, tanto en el nivel secundario como universitario. La enseñanza tradicional, centrada en clases magistrales y resolución de ejercicios, no siempre logra transformar concepciones intuitivas sobre el movimiento y la fuerza. Como resultado, muchos estudiantes ingresan a la educación superior con dificultades importantes para comprender los principios básicos de la mecánica clásica, lo que limita su desempeño en carreras de orientación científica y tecnológica (Varas Flores et al., 2018).

A este panorama se suma una problemática estructural: la formación inicial deficiente de los futuros docentes de física. Numerosos estudios coinciden en que los programas de formación docente suelen presentar una fragmentación entre el conocimiento disciplinar, didáctico y pedagógico, lo que afecta la capacidad de los futuros profesores para diseñar secuencias didácticas fundamentadas y responder a las dificultades conceptuales de los estudiantes (Montino & Chiabrando, 2015). La enseñanza de la mecánica, en particular, suele abordarse



desde una perspectiva algorítmica y descontextualizada, priorizando la formalización matemática por sobre la reflexión didáctica y epistemológica. Esta situación compromete la calidad de la enseñanza desde el nivel formativo y refuerza la necesidad de enfoques integradores que vinculen teoría, práctica y comprensión pedagógica. (Bauer et al., 2025) Diversas estrategias didácticas han sido propuestas para abordar esta problemática. Una de las más destacadas es la instrucción entre pares, propuesta por Eric Mazur, que promueve el debate y la colaboración entre estudiantes como vía para alcanzar una comprensión profunda de los conceptos científicos (Hernández Campos & Murillo-Quirós, 2019). Esta metodología permite que los estudiantes verbalicen sus razonamientos, confronten ideas y reestructuren su conocimiento, proceso que se alinea con los fundamentos de la teoría de los campos conceptuales de Vergnaud (Irineu et al., 2022). Sin embargo, su aplicación enfrenta limitaciones prácticas, como la heterogeneidad en el nivel de conocimientos, la falta de tiempo en el aula y la escasa formación docente en enfoques innovadores.

En este escenario, la inteligencia artificial emerge como una herramienta con alto potencial pedagógico. Investigaciones recientes han comenzado a explorar el uso de agentes conversacionales y sistemas de tutoría inteligente para ofrecer apoyo personalizado en el aprendizaje de la física (Kieser et al., 2023; Vergara González & Carrillo Rosúa, 2023). Estos sistemas pueden adaptarse al ritmo y estilo de aprendizaje de cada estudiante, proporcionando explicaciones dinámicas, retroalimentación inmediata y ejercicios interactivos que favorecen la comprensión conceptual (Mahligawati1 et al., 2023). Además, la inteligencia artificial puede asumir el rol de un “par” en el contexto de la instrucción entre pares, guiando al estudiante hacia concepciones científicas correctas y evitando la reproducción de errores comunes.

El presente estudio tiene como objetivo analizar el impacto del uso de inteligencia artificial en el aprendizaje de la mecánica newtoniana, a través de una estrategia didáctica basada en la instrucción entre pares. Para ello, se compararán los niveles de aprendizaje conceptual entre dos grupos de estudiantes de tercer semestre de la carrera de Licenciatura en Pedagogía de las Ciencias Experimentales con mención en Física y Matemática de la Universidad de Guayaquil. En el grupo de control se aplicará la metodología tradicional de instrucción entre pares, mientras que, en el grupo experimental, el compañero de trabajo será sustituido por un

agente conversacional basado en inteligencia artificial (ChatGPT). El aprendizaje se evaluará mediante la aplicación del instrumento Force and Motion Conceptual Evaluation (FMCE), tanto en el pretest como en el postest, con el fin de determinar la eficacia de la intervención para modificar concepciones erróneas y fortalecer la comprensión conceptual.

Dada la creciente presencia de la inteligencia artificial en los entornos educativos, este estudio busca aportar evidencia empírica sobre su aplicación en el campo de la enseñanza de la física. A su vez, pretende contribuir al diseño de propuestas didácticas que integren tecnologías emergentes con metodologías activas, respondiendo a las necesidades de contextos educativos donde los desafíos pedagógicos demandan soluciones innovadoras y adaptables.

Materiales y métodos

Materiales

El aprendizaje conceptual fue medido a través del Force and Motion Conceptual Evaluation (FMCE), desarrollado por Thornton y Sokoloff (1998). Este instrumento consta de 47 ítems de opción múltiple diseñados para diagnosticar las concepciones alternativas de los estudiantes sobre fuerza, aceleración, velocidad y el cumplimiento (o no) de las leyes de Newton en diferentes situaciones físicas. El FMCE ha sido validado empíricamente en múltiples investigaciones en educación en física (Hewagallage et al., 2022), y se ha consolidado como uno de los instrumentos más robustos para la evaluación conceptual de la mecánica clásica. Su estructura permite identificar patrones de pensamiento no científicos que persisten aún después de una instrucción formal, lo que lo hace especialmente útil para valorar el impacto de metodologías como la instrucción entre pares o el uso de tecnologías emergentes.

Por otra parte, se incorporó en el grupo de experimentación el uso de ChatGPT (versión GPT-4 de OpenAI) como agente conversacional pedagógico. Esta inteligencia artificial basada en lenguaje natural se utilizó como un “par virtual”, capaz de interactuar con el estudiante, formular contraargumentos, dar retroalimentación inmediata y ofrecer explicaciones accesibles a los niveles de comprensión individuales. (Küchemann et al., 2023). Los agentes conversacionales se han consolidado como una tendencia creciente en la educación mediada por tecnología. Su aplicación en contextos educativos ha mostrado potencial para fomentar



el aprendizaje autónomo, facilitar la resolución de dudas inmediatas y promover la reflexión metacognitiva (Chae et al., 2023; Chen et al., 2020).

Con el fin de asegurar la equivalencia curricular entre ambos grupos, se utilizaron materiales instruccionales estandarizados, diseñados por el docente-investigador y validados por especialistas en didáctica de la física. Estos incluyeron:

- Presentaciones expositivas sobre los contenidos clave de la mecánica newtoniana, centradas en la claridad conceptual y en evitar la sobrecarga cognitiva.
- Guías de ejercicios cualitativos, orientadas al análisis conceptual y al uso de modelos mentales científicos.
- Preguntas tipo ConcepTest, diseñadas conforme al modelo de Mazur (2014), dirigidas a estimular el razonamiento, la autorregulación y la discusión entre pares.
- Material de lectura complementario, accesible en formato digital, con recursos ajustados al nivel cognitivo de los participantes.

Todos los materiales fueron revisados y ajustados previamente para garantizar su coherencia didáctica, su adecuación al nivel universitario y su alineación con los objetivos del estudio.

Método

La investigación adoptó un enfoque cuantitativo, con un diseño cuasiexperimental de tipo pretest-postest con grupos no equivalentes, lo cual permite evaluar el efecto de una intervención educativa sin necesidad de asignación aleatoria de los participantes (Ñaupas Paitán et al., 2018). Esta elección metodológica se justifica por el uso de grupos intactos en contextos reales de aula (Pinargote et al. 2024).

La intervención se llevó a cabo durante cinco sesiones de dos horas cada una y se realizó en dos grupos: uno de control y otro experimental, donde ambos grupos recibieron instrucción sobre los mismos contenidos del bloque de mecánica clásica: movimiento en una y dos dimensiones, leyes de Newton y sus aplicaciones, y energía de un sistema.

En la primera sesión, ambos grupos completaron el FMCE como pretest. Posteriormente, se aplicó la intervención durante las siguientes tres sesiones, donde el docente implementó la metodología de la instrucción entre pares que de acuerdo con Mazur (1997) citado por Hejnová & Králík (2022) y Budini et al., (2018) se ejecuta mediante los siguientes pasos:



- El docente presenta a los estudiantes el concepto a analizar, enfocándose en su comprensión cualitativa más que en su formulación matemática. Para luego formular una pregunta desafiante de opción múltiple que se encuentran en alguna plataforma digital, para su rápido conteo y presentación de estadística, los estudiantes buscan una solución y votan de manera individual. Estas preguntas tendrán como opciones de respuesta los errores más comunes asociados a las concepciones de los estudiantes.
- A partir del conteo de respuestas, el mediador, invita a entablar una conversación entre aquellos estudiantes que escogieron alternativas totalmente diferentes, pues busca que escuchen y analicen sus perspectivas, para en base a ello seleccionar la respuesta correcta en la siguiente votación; lo que cambiará el esquema inicial.
- Por último, el docente retroalimentará el concepto propuesto, resaltando el porqué de las respuestas incorrectas y justificando a la respuesta correcta.

Es importante resaltar que si la cantidad de estudiantes que han escogido la respuesta correcta, en la primera ejecución del test, no supera a un 30%, se debe revisar el concepto una vez más junto al docente y volver a votar para dar inicio a esta metodología. Sin embargo, si existe un 70% de la población que tiene la respuesta correcta, no es necesario la interacción entre pares y se da paso automáticamente a la retroalimentación del docente. Por lo tanto, este proceso se realizará si las respuestas superan el 30% y son inferiores al 70%.

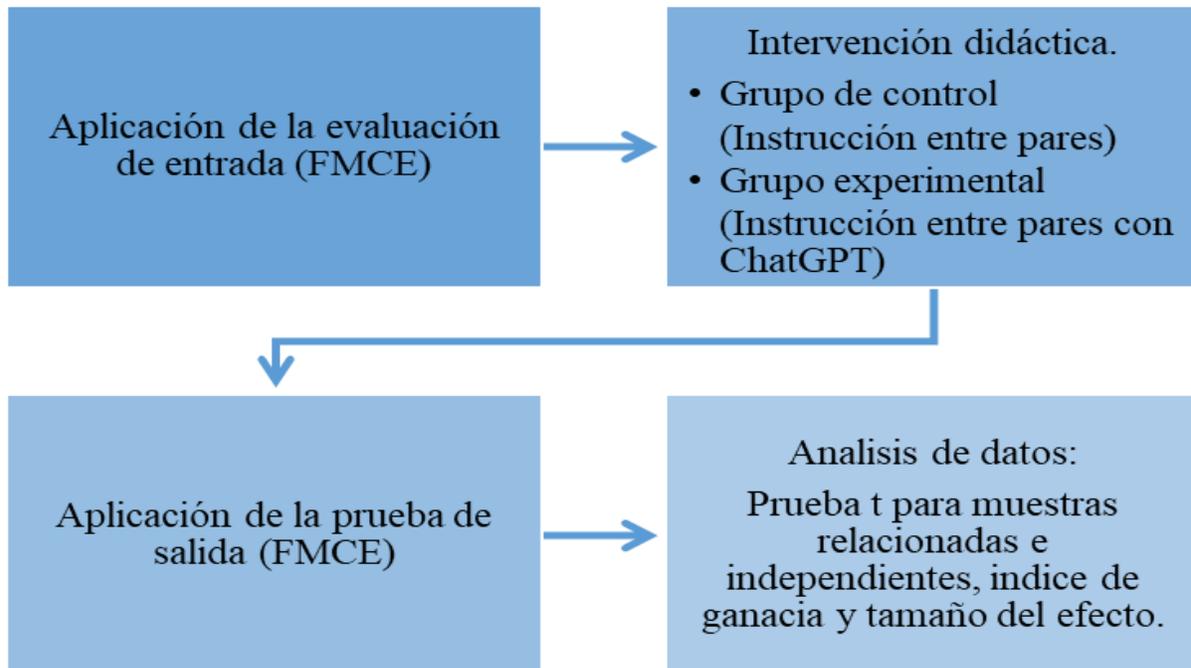
Por su parte, el grupo experimental trabajó también bajo el modelo de instrucción entre pares, pero con una variante clave: en lugar de discutir las preguntas conceptuales con un compañero humano, los estudiantes interactuaban con la inteligencia artificial ChatGPT, como su “par” académico, esta inteligencia artificial es capaz de generar explicaciones, responder preguntas, ofrecer retroalimentación inmediata y simular una conversación con base en los argumentos del estudiante. Al inicio de la sección se instruyó a los participantes del grupo experimental sobre el uso ético, técnico y pedagógico de la herramienta, y se aseguró las condiciones de conectividad, acceso y soporte técnico necesarios durante las sesiones de aprendizaje.

En la última sesión se aplicó el FMCE como test de salida. Para el análisis de los resultados obtenidos a partir de las evaluaciones, se utilizó el software SPSS versión 26, ampliamente reconocido en investigación educativa por sus capacidades para realizar análisis descriptivos

e inferenciales robustos (Field , 2018). Este programa permitió analizar estadísticos descriptivos (media, desviación estándar) e inferenciales. Para determinar el efecto de la intervención dentro de cada grupo se utilizó la prueba t para muestras relacionadas, y para la comparación entre grupos se aplicó la prueba t para muestras independientes, con un nivel de significancia de $\alpha = 0.05$. Además, se calculó el tamaño del efecto mediante el coeficiente d de Cohen, con el fin de estimar la magnitud de las diferencias encontradas (Cohen, 1988). Complementariamente, se aplicó el índice de ganancia normalizada propuesto por Hake (1998) como indicador adicional del progreso conceptual logrado en ambas condiciones experimentales. La Figura 1 resume de manera esquemática el procedimiento seguido durante la investigación.

Figura 1.

Esquema del procedimiento experimental de la investigación.



Fuente: Elaboración propia.

Resultados

Descripción de la muestra

La muestra estuvo compuesta por estudiantes del tercer semestre de la carrera de Pedagogía de las Ciencias Experimentales, mención Matemáticas y Física, de la Universidad de Guayaquil. Se trabajó con dos grupos intactos pertenecientes a la asignatura Física 1, seleccionados mediante un muestreo no probabilístico por conveniencia, en función de su disponibilidad y organización curricular.

El grupo experimental estuvo conformado por 29 estudiantes del turno matutino, mientras que el grupo de control incluyó a 26 estudiantes del turno nocturno. Ambos grupos compartían el mismo plan de estudios, contenidos temáticos y nivel académico, centrados en el bloque de mecánica clásica. La asignación a los grupos respondió a la estructura organizativa institucional, lo que permitió aplicar un diseño cuasiexperimental con grupos no equivalentes, bajo condiciones curriculares homogéneas. Se tomaron medidas para controlar variables externas que pudieran influir en los resultados, de modo que la principal diferencia entre los grupos residiera exclusivamente en la estrategia de enseñanza aplicada durante la intervención.

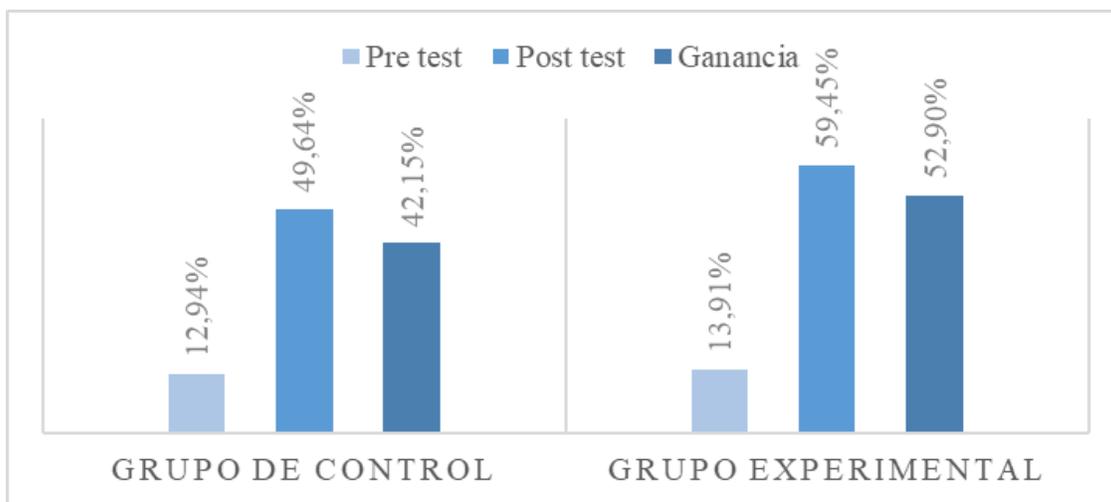
Análisis de los Resultados

En la Figura 2 se resumen los porcentajes de respuestas correctas en el FMCE para ambos grupos. El grupo de control obtuvo un promedio de 12,94 % en el pretest y 49,64 % en el posttest, con una ganancia normalizada total de 0,418. Por su parte, el grupo experimental pasó de 13,91 % a 59,45 %, logrando una ganancia normalizada de 0,525. Ambos grupos muestran una mejora significativa tras la intervención.

Figura 2.



Porcentaje de aciertos y ganancia en el FMCE por grupo.



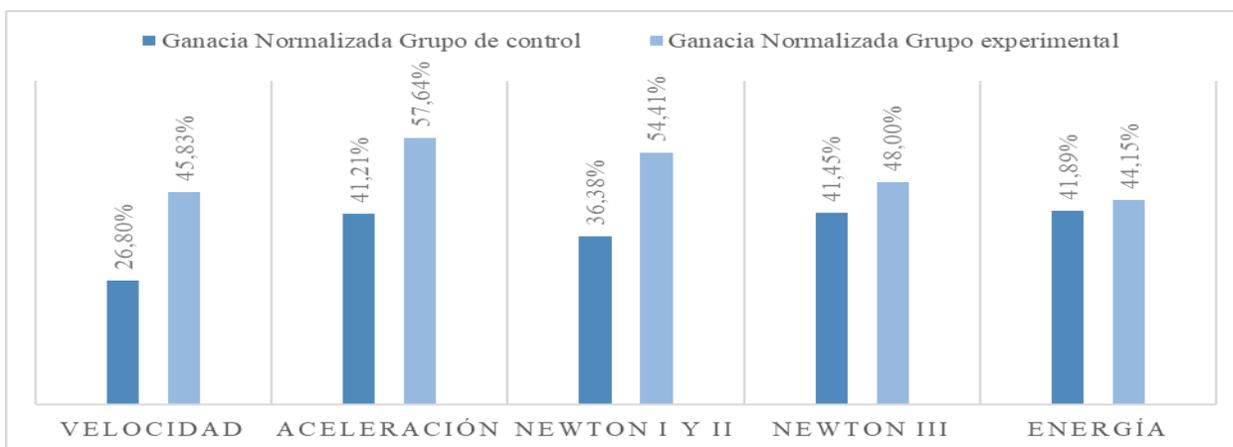
Fuente: Elaboración propia.

Nota: La ganancia corresponde al índice de Hake y se muestra en porcentaje.

La Figura 3 presenta los resultados desagregados por categorías del FMCE, siguiendo la clasificación de T. Smith y Wittmann (2008). En todas las categorías —Velocidad, Aceleración, Newton I y II, Newton III y Energía— se evidencia una mejora en ambos grupos, aunque con mayores ganancias en el grupo experimental.

Figura 3.

Ganancia normalizada en el FMCE por categoría conceptual y grupo.



Fuente: Elaboración propia.

Nota: La ganancia corresponde al índice de Hake y se muestra en porcentaje.



Los avances más pronunciados en el grupo experimental se observan en las categorías de Aceleración (57,64 %) y Newton I y II (54,41 %), lo cual indica una mejora significativa en conceptos centrales del modelo newtoniano. Aunque ambos grupos presentan progreso, el grupo experimental muestra ganancias superiores en todas las categorías evaluadas.

Previo al análisis inferencial, se evaluó el supuesto de normalidad de las distribuciones mediante las pruebas de Shapiro-Wilk, cuyos resultados se presentan en la Tabla 1. Ninguna de las variables presentó desviaciones significativas de la normalidad ($p > 0,05$), por lo que se justificó el uso de pruebas paramétricas para los análisis posteriores.

Tabla 1

Prueba de normalidad Shapiro-Wilk por grupo y momento.

	Estadístico	gl	p
Pretest – grupo de control	0,934	26	0,096
Pretest – grupo experimental	0,942	26	0,149
Postest - grupo de control	0,936	26	0,108
Postest - grupo experimental	0,941	26	0,139

Fuente: Elaboración propia.

La Tabla 2 muestra los resultados de la prueba t para muestras relacionadas, aplicada para comparar el rendimiento de los estudiantes dentro de cada grupo antes y después de la intervención. En ambos casos, las diferencias fueron estadísticamente significativas ($p < 0,001$), indicando un progreso claro en el aprendizaje conceptual tras la aplicación de la estrategia didáctica.

Tabla 2

Prueba t para muestras relacionadas (pretest y postest)

	I.C. 95%		t	gl	p
	Inferior	Superior			
Pretest – Postest Grupo de control	-14,154	-10,077	-12,242	25	0,000
Pretest – Postest Grupo experimental	-17,272	-12,797	-13,763	28	0,000

Fuente: Elaboración propia.



Adicionalmente, se calculó el tamaño del efecto de Cohen (d) para cuantificar la magnitud del cambio dentro de cada grupo. El grupo de control presentó un tamaño del efecto de $d = 2,40$, mientras que el grupo experimental alcanzó $d = 2,56$, lo que corresponde a efectos muy grandes según los criterios establecidos por Cohen (1988). Esto puede explicarse por la gran diferencia entre los puntajes de pretest y postest, así como por la baja dispersión de las diferencias. Esto indica que la mejora fue tanto significativa como uniforme entre los estudiantes, reforzando la solidez del efecto observado.

Finalmente, la Tabla 3 resume los resultados de la prueba t para muestras independientes, utilizada para comparar el rendimiento del grupo de control y el grupo experimental, tanto en el pretest como en el postest. En el pretest, la prueba de Levene arrojó un valor $p = 0,507$, lo que indica que se pueden asumir varianzas iguales. La prueba t no evidenció diferencias estadísticamente significativas ($p = 0,552$), lo que sugiere que ambos grupos partían de un nivel comparable de conocimientos antes de la intervención.

Tabla 3

Prueba t para muestras independientes (grupo control vs. experimental).

	Prueba de Levene		Prueba t para muestras independientes					
	F	p	t	gl	p	I.C. 95%		
						Inferior	Superior	
Pretest	0,447	0,507	-0,598	53	0,552	-1,380	0,746	
Postest	1,907	0,173	-2,462	53	0,017	-5,872	-0,600	

Fuente: Elaboración propia.

En el postest, la prueba de Levene fue $p = 0,173$, permitiendo mantener la asunción de igualdad de varianzas. En este caso, la prueba t arrojó una diferencia significativa entre ambos grupos ($p = 0,017$), con una diferencia de medias de 3,24 puntos a favor del grupo experimental. El cálculo del tamaño del efecto intergrupar arrojó un valor de $d = 0,666$, lo que corresponde a un efecto moderado-alto (Cohen, 1988). Este resultado indica que la diferencia observada no solo es estadísticamente significativa, sino también educativamente relevante.



Discusión

Los resultados obtenidos en esta investigación muestran que tanto la instrucción entre pares tradicional como la mediada por inteligencia artificial (IA) produjeron mejoras significativas en el aprendizaje conceptual de la mecánica newtoniana. Esta afirmación se sustenta en los datos obtenidos del FMCE, que evidenciaron un aumento notable en el porcentaje de respuestas correctas en ambos grupos tras la intervención, con diferencias estadísticamente significativas ($p < 0,001$) y tamaños del efecto muy grandes ($d = 2,40$ para el grupo control y $d = 2,56$ para el grupo experimental).

Uno de los principios pedagógicos más relevantes que se confirma con este estudio es la efectividad del aprendizaje activo centrado en el estudiante. La instrucción entre pares, como estrategia basada en la interacción, el cuestionamiento y la co-construcción del conocimiento, ha demostrado ser una metodología poderosa para favorecer el cambio conceptual (Zhang, Ding, & Mazur, 2017). Este estudio extiende dicho principio al contexto digital, mostrando que un agente conversacional como ChatGPT puede actuar como sustituto funcional de un compañero humano, facilitando el mismo proceso dialógico con resultados incluso superiores.

El análisis comparativo entre los grupos mostró una ganancia normalizada superior en el grupo experimental ($g = 0,53$ frente a $g = 0,42$), lo cual, acompañado de un tamaño del efecto intergrupo de $d = 0,666$, sugiere que el uso de inteligencia artificial no solo complementa, sino que potencia la estrategia instruccional. Esta relación directa entre mediación tecnológica y mejora en el aprendizaje permite generalizar la idea de que los entornos de aprendizaje mediados por IA pueden ser efectivos para promover comprensión conceptual profunda, especialmente en campos abstractos como la física (Jadhav & Bhanud, 2025).

Pese a los resultados positivos, hubo categorías del FMCE —como Energía— en las que la diferencia entre grupos fue menor que en otras. Esto sugiere que ciertos conceptos, particularmente aquellos que requieren una interpretación más formal o matemática, podrían beneficiarse de estrategias adicionales como simulaciones interactivas, prácticas de laboratorio o visualizaciones dinámicas (Rahim & Ali, 2025).

Otro aspecto no resuelto es la manera en que los estudiantes se relacionan cognitivamente con el agente conversacional. Si bien se obtuvieron mejoras, no se evaluó en profundidad el



tipo de interacciones, la calidad de las explicaciones generadas por la IA, ni la percepción del estudiante sobre su efectividad como “par”. Estos factores podrían influir en la motivación, la autorregulación y el nivel de comprensión logrado (Sperling & Lincoln, 2024) Los hallazgos coinciden con estudios que han demostrado el impacto positivo de la instrucción entre pares en la enseñanza de la física universitaria (Hernández & Murillo, 2019), así como con investigaciones que destacan el potencial de los agentes conversacionales para facilitar el razonamiento científico, promover el conflicto cognitivo y guiar la autorreflexión (Steinert et al., 2024)

Asimismo, este estudio se alinea con los postulados de la teoría de los campos conceptuales de Vergnaud descrito por Irineu et al., (2022), al mostrar que la intervención favoreció el reemplazo de concepciones alternativas por estructuras más formalizadas. El uso de ChatGPT actuó como desencadenante del conflicto cognitivo necesario para que el estudiante replantee sus esquemas de interpretación física, lo cual es consistente con los modelos constructivistas de aprendizaje.

Desde una perspectiva teórica, esta investigación aporta evidencia sobre la posibilidad de integrar la inteligencia artificial dentro de marcos pedagógicos basados en interacción y argumentación. El papel del docente se transforma en el de diseñador de experiencias, mientras que la IA puede ocupar un lugar como mediador pedagógico, complementando los procesos de enseñanza-aprendizaje en modalidades presenciales, híbridas o virtuales.

En resumen, esta investigación aporta varias conclusiones respaldadas empíricamente:

- Ambos grupos mejoraron significativamente su comprensión conceptual, lo cual valida la efectividad general de la instrucción entre pares (prueba t para muestras relacionadas, $p < 0,001$; $d > 2,4$).
- El grupo experimental obtuvo mejores resultados que el grupo control, tanto en ganancia normalizada como en el postest global (prueba t intergrupala, $p = 0,017$; $d = 0,666$).
- La IA puede actuar como mediador eficaz, promoviendo aprendizajes relevantes mediante interacción y retroalimentación inmediata.
- La estrategia potencia el cambio conceptual en coherencia con teorías constructivistas como los campos conceptuales.



Conclusiones

Los hallazgos de esta investigación confirman que la instrucción entre pares es una estrategia didáctica efectiva para promover el aprendizaje conceptual en física, específicamente en la mecánica newtoniana. Tanto el grupo de control como el experimental mostraron mejoras significativas tras la intervención, aunque el grupo que trabajó con inteligencia artificial como par virtual obtuvo un desempeño superior, evidenciado por una mayor ganancia conceptual y un tamaño del efecto moderado-alto. Esto sugiere que los agentes conversacionales como ChatGPT pueden complementar con éxito las metodologías activas centradas en el estudiante.

La incorporación de inteligencia artificial como mediador pedagógico permitió a los estudiantes reflexionar, argumentar y reorganizar sus ideas previas, favoreciendo el cambio conceptual dentro del marco de la teoría de los campos conceptuales. Esta intervención se presenta como una alternativa viable y escalable en contextos educativos con limitaciones de tiempo, recursos o disponibilidad de interacción humana constante.

Se recomienda considerar la inclusión de agentes conversacionales en el diseño de experiencias de aprendizaje en ciencias, particularmente en instituciones de educación superior. Asimismo, futuras investigaciones podrían explorar el impacto de este tipo de herramientas en otras disciplinas o niveles educativos, así como profundizar en el análisis cualitativo de las interacciones entre estudiantes e inteligencia artificial para comprender mejor sus efectos cognitivos y emocionales.

Referencias bibliográficas

- Artamónova, I., Mosquera-Mosquera, J., & Mosquera-Artamónov, J. (2017). Aplicación de force concept inventory en América Latina para la evaluación de la comprensión de los conceptos básicos de mecánica a nivel universitario. *Revista Educación en Ingeniería*, 56-63.
- Bauer, A., Gleichmann, J., & Bitzenbauer, P. (2025). Toward a more coherent and profession-related physics teacher education: Linking subject-specific and physics education content in the study entry phase. *American Journal of Physics*, 250-255.



- Budini, N., Marino, L., Carreri, A., Cámara, C., & Giorgi, S. (2018). Percepciones de estudiantes luego de implementar “Instrucción entre Pares” en un curso de Física I. *Revista de enseñanza de la física*, 141-149.
- Chae, H., Kim, M., Kim, C., Jeong, W., Kim, H., Lee, J., & Yeo, J. (2023). TUTORING: Instruction-Grounded Conversational Agent for Language Learners. *The Thirty-Seventh AAAI Conference on Artificial Intelligence* (págs. 16413-16415). Washington, DC: AAAI Press.
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, 8, 75264-75278. doi: <https://doi.org/10.1109/ACCESS.2020.2988510>
- Field, A. (2018). *Discovering Statistics Using IBM SPSS Statistics*. SAGE Publications.
- Hake, R. (1998). Interactive-engagement versus traditional methods: A six-thousand-student survey of mechanics test data. *American Journal of Physics*, 66(1), 64–74.
- Hejnová, E., & Králík, J. (2022). Use of the peer instruction method in blended learning. *DIDACTIC TRANSFER OF PHYSICS KNOWLEDGE THROUGH DISTANCE EDUCATION: DIDFYZ 202* (pág. 030009). Terchová: AIP Publishing.
- Hernández Campos, M., & Murillo-Quirós, N. (2019). Instrucción entre pares y enseñanza justo a tiempo: una experiencia en la enseñanza de la Física en educación superior. *Cuadernos de Investigación UNED*, 11(2), 130-135. doi: <https://doi.org/10.22458/urj.v11i2.2310>
- Hewagallage, D., Christman, E., & Stewart, J. (2022). Examining the relation of high school preparation and college achievement to conceptual understanding. *Physical Review Physics Education Research*, 18(1), 010149. doi: <https://doi.org/10.1103/PhysRevPhysEducRes.18.010149>
- Irineu, J., Roberto Junior, A., Silva Oliveira, A. J., & Mendonça Oliveira, C. B. (2022). Astronomy as a Tool for Learning the laws of Physics: Theory of Conceptual fields by Vergnaud. *International Journal of Advanced Engineering Research and Science*, 9(7), 35-60. doi:10.22161/ijaers.97.5
- Jadhav, S. B., & Bhanud, K. D. (2025). Exploring the conversational landscape: A survey of artificial intelligence-based chatbot development. *6TH INTERNATIONAL*



- Kieser, F., Wulff, P., Kuhn, J., & Küchemann, S. (2023). Educational data augmentation in physics education research using ChatGPT. *Physical Review Physics Education Research*, 19(2), 020150. doi:10.1103/PhysRevPhysEducRes.19.020150
- Küchemann, S., Steinert, S., Revenga, N., Schweinberger, M., Dinc, Y., Avila, K., & Kuhn, J. (2023). Can ChatGPT support prospective teachers in physics task development? *Physical Review Physics Education Research*, 19(2), 020128. doi: <https://doi.org/10.1103/PhysRevPhysEducRes.19.020128>
- Lino-Calle, V., Barberán-Delgado, J., Lopez-Fernández, R., & Gómez-Rodríguez, V. (2023). Analítica del aprendizaje sustentada en el Phet Simulations como medio de enseñanza en la asignatura de Física. *Journal Scientific MQR Investigar*, 7(3), 2297–2322. <https://doi.org/10.56048/MQR20225.7.3.2023.2297-2322>
- Mahligawati¹, F., Allanas, E., Butarbutar, M., & Nordin, N. (2023). Artificial intelligence in Physics Education: a comprehensive literature review. *Journal of Physics: Conference Series*. 12th International Physics Seminar 2023 (págs. 1-6). IOP Publishing.
- Mazur, E. (1997). *Peer Instruction: A User's Manual*. United States of America.: Prentice Hall.
- Mazur, E. (2014). *Peer Instruction: A User's Manual*. United States of America: Pearson Education Limited.
- Montino, M., & Chiabrando, L. (2015). Repensando las Leyes de Newton en la formación de profesores. *Revista de enseñanza de la física.*, 669-674.
- Ñaupas Paitán, H., Valdivia Dueñas, M. R., Palacios Vilela, J. J., & Romero Delgado, H. E. (2018). *Metodología de la investigación*. Bogotá: Ediciones de la U.
- Pinargote, J., Lino, V., & Vera, B. (2024). Python en la enseñanza de las Matemáticas para estudiantes de nivelación en Educación Superior. *MQR Investigar*, 8(3), 3966–3989. <https://doi.org//10.56048/MQR20225.8.3.2024.3966-3989>
- Rahim, H. H., & Ali, Q. A. (2025). Enhancing practical learning experiences: A systematic approach to designing and evaluating a virtual lab simulation model using interactive

multimedia technology for University students. THE SECOND INTERNATIONAL CONFERENCE ON SCIENTIFIC RESEARCH AND INNOVATION 2023 (2ICSRI2023) (pág. 030005). Cincinnati: AIP Publishing .

- Robertson, A., Goodhew, L., Bauman, L., Hansen, B., & Alesandrini, A. (2023). Identifying student conceptual resources for understanding physics: A practical guide for researchers. *Physical Review Physics Education Research*, 19(2), 020138. doi: <https://doi.org/10.1103/PhysRevPhysEducRes.19.020138>
- Rosales, J. J., & Sulaiman, F. (2020). The development of Integrated STEM-PBL physics module for learning classical mechanics in secondary education. *Solid State Technology*, 63(6), 19410-19433.
- Sperling, A., & Lincoln, J. (2024). Artificial intelligence and high school physics. *The Physics Teacher*, 314–315.
- Steinert, S., Avila, K., Kuhn, J., & Küchemann, S. (2024). Using GPT-4 as a guide during inquiry-based learning. *The Physics Teacher*, 618–619.
- Thornton, R., & Sokoloff, D. (1998). Assessing student learning of Newton's laws: The Force and Motion Conceptual Evaluation and the Evaluation of Active Learning Laboratory and Lecture Curricula. *American Journal of Physics*, 338–352.
- Varas Flores, M., Villalva Cárdenas, E., & Avilés Monroy, J. (2018). Errores conceptuales, actitudes y creencias sobre el aprendizaje de la Física. *Revista Espacios*, 39(30), 21-29.
- Vergara González, R. M., & Carrillo Rosúa, F. J. (2023). Uso de Inteligencia Artificial para diseñar propuestas didácticas de Física y Química en Educación Secundaria. CIVINEDU 2023, 7th International Virtual Conference on Educational Research and Innovation (págs. 125-131). Madrid: REDINE: Red de Investigación e Innovación Educativa.
- Zhang, P., Ding, L., & Mazur, E. (2017). Peer Instruction in introductory physics: A method to bring about positive changes in students' attitudes and beliefs. *Physical Review Physics Education Research*, 010104.

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.