

UNIVERSIDAD PARA EL DESARROLLO ANDINO

ESCUELA DE POSGRADO

**MAESTRÍA EN DOCENCIA UNIVERSITARIA Y GESTIÓN
EDUCATIVA**



**EFFECTO DE UNA ESTRATEGIA DIDÁCTICA MEDIADA CON INTELIGENCIA
ARTIFICIAL EN EL APRENDIZAJE DE MATEMÁTICA DISCRETA EN
ESTUDIANTES DE CIENCIA DE DATOS DE UNA UNIVERSIDAD LIMEÑA , 2026**

Tesis para optar el grado académico de

MAESTRO EN DOCENCIA UNIVERSITARIA Y GESTIÓN EDUCATIVA

AUTOR

Br. Porras Vilcahuamán Yimy José

<https://orcid.org/0000-0003-3756-3045>

ASESOR

Mg. Karina Eddmy Madrid Gomez

<https://orcid.org/0000-0002-1831-736X>

LÍNEA DE INVESTIGACIÓN

Metodologías didácticas, innovadoras e inclusivas

LIMA – PERÚ

2026

N.º 070-2026-AIBR-II-UDEA

CONSTANCIA

DE SIMILITUD DE TRABAJOS DE TESIS POR EL SOFTWARE DE TURNITIN

El Instituto de Investigación, hace constar por la presente, que la Tesis titulada **“EFECTO DE UNA ESTRATEGIA DIDÁCTICA MEDIADA CON INTELIGENCIA ARTIFICIAL EN EL APRENDIZAJE DE MATEMÁTICA DISCRETA EN ESTUDIANTES DE CIENCIA DE DATOS DE UNA UNIVERSIDAD LIMEÑA, 2026”**.

Autor : **YIMY JOSÉ PORRAS VILCAHUAMÁN**

Programa : **ESCUELA DE POSGRADO**

Mención : **MAESTRIA EN DOCENCIA UNIVERSITARIA Y GESTIÓN EDUCATIVA**

Asesora : **Mg. KARINA EDDMY MADRID GOMEZ**

Que fue presentada en fecha **02/07/2026**, después de haberse realizado el análisis con el software de Turnitin, excluyendo la bibliografía y similitudes menores a 1 %, presenta un porcentaje de similitud de **8%** el día 2 de julio de 2026.

En tal sentido, de acuerdo con los criterios establecidos en el Reglamento de Grados y Títulos, se declara que la tesis cumple con el porcentaje aceptable de similitud.

En señal de conformidad y verificación se firma la presente constancia.

Lircay, 2 de julio de 2026.



**Asistente de Investigación, Responsable
de Repositorio y Biblioteca
Instituto de Investigación**

CONSTANCIA DE APROBACIÓN DE ASESOR

En condición de asesor(a) designado de la tesis titulada: **“EFECTO DE UNA ESTRATEGIA DIDÁCTICA MEDIADA CON INTELIGENCIA ARTIFICIAL EN EL APRENDIZAJE DE MATEMÁTICA DISCRETA EN ESTUDIANTES DE CIENCIA D EDATOS DE UNA UNIVERSIDAD LIMEÑA , 2026 ”** cuyo autor es **YIMY JOSÉ PORRAS VILCAHUAMÁN** para optar por el grado académico de Maestro en **MAESTRO EN DOCENCIA UNIVERSITARIA Y GESTIÓN EDUCATIVA**, luego de la revisión exhaustiva al contenido del documento, doy fe y considero que se encuentra apto para ser aprobado y con méritos suficientes para ser sometido para la sustentación.

En señal de conformidad se firma y sella la presente constancia.

Lugar, 30 de junio de 2026



Firma

Asesor: Mg. Karina Eddmy Madrid Gomez

ACTA DE SUSTENTACIÓN DE TESIS

Nº 028/2026

En la ciudad de Lircay, provincia de Angaraes, Región Huancavelica, a los 18 días del mes de junio del año 2026, siendo las 15:00 p.m horas, en la sesión virtual en la plataforma de Google Meet de la Escuela de Posgrado de la Universidad para el Desarrollo Andino se instaló el Jurado designado con Resolución Directoral N.º 028/2026 de fecha 28 de mayo de 2026, teniendo como Miembros de Jurado:

PRESIDENTE : Rocio Tito Gomez,
SECRETARIO : José Ragas Rojas
VOCAL : Reynaldo Panduro Llerena

Con la finalidad de llevar a cabo el acto académico de sustentación de tesis del estudiante: **YIMY JOSE PORRAS VILCAHUAMAN**, de la Escuela de Posgrado, quien sustenta la tesis titulada **“EFECTO DE UNA ESTRATEGIA DIDÁCTICA MEDIADA CON INTELIGENCIA ARTIFICIAL EN EL APRENDIZAJE DE MATEMÁTICA DISCRETA EN ESTUDIANTES DE CIENCIA DE DATOS DE UNA UNIVERSIDAD LIMEÑA , 2026”**, para optar por el grado académico de Maestro en Docencia Universitaria y Gestión Educativa, bajo la modalidad de tesis.

Luego, de haber absuelto las preguntas que fueron formuladas por los Miembros del Jurado, se llegó al siguiente resultado:

Aprobado por	:	☒ Unanimidad	☐ Mayoría		
	:	☒ Con observación	☐ Sin observación		
Mención	:	☒ Excelente	☐ Muy bueno	☐ Bueno	☐ Regular
Desaprobado por	:	☐ Unanimidad	☐ Mayoría		

Observaciones:

- Incluir la estrategia didáctica en alguna parte de la investigación escrita.
- Sugerencia: Incluir un grupo de control si se desea ampliar la investigación.

En conformidad a lo actuado firmamos al pie.



PRESIDENTE



SECRETARIO



VOCAL

Dedicatoria

A mi madre, Ana María, por ser mi raíz y mi fortaleza; por tu amor incondicional, tu paciencia y tu fe constante en mí, incluso en los días más difíciles.

A mi padre, Marco, por tu ejemplo de lucha y responsabilidad, por enseñarme a perseverar y por el apoyo que, de distintas maneras, me ha acompañado en este camino.

A mi hijo, Samir, mi mayor motivación y la razón más pura para seguir creciendo. Cada paso de este proceso lo di pensando en el futuro que mereces.

A mi abuelita, Mamita María, que hoy descansa en el cielo, por tu amor inmenso, tus consejos y tu ternura. Tu recuerdo vive en mí y sigue guiando mis pasos.

Con todo mi cariño y gratitud.

Agradecimientos

Agradezco a la Universidad para el Desarrollo Andino y a la Escuela de Posgrado del Programa de Maestría en Docencia Universitaria y Gestión Educativa, por brindarme la oportunidad de continuar mi formación académica y profesional.

A mi asesora, Mg. Karina Madrid Gómez, por su orientación constante, por su paciencia durante el desarrollo de esta investigación y por cada una de sus observaciones, que contribuyeron a fortalecer y mejorar este trabajo.

A los docentes de la maestría, por compartir sus conocimientos, experiencias y reflexiones, que enriquecieron mi formación y me permitieron comprender la educación desde una perspectiva más amplia y crítica.

A todos ellos, expreso mi más sincero agradecimiento.

RESUMEN

El objetivo de la investigación fue determinar el efecto de una estrategia didáctica mediada por inteligencia artificial (IA) en el aprendizaje de Matemática Discreta en estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, en 2026. El estudio fue de tipo aplicado, con enfoque cuantitativo y diseño preexperimental de un solo grupo con medición pretest y posttest. La población estuvo conformada por 150 estudiantes y la muestra, bajo criterio censal, incluyó a la totalidad de la población accesible ($n = 150$). La intervención consistió en la aplicación de un protocolo de Ingeniería de Prompts como andamiaje cognitivo en los contenidos de lógica proposicional, relaciones y teoría de grafos. Para la recolección de datos se empleó una prueba de conocimientos validada mediante juicio de expertos y un cuestionario de percepción tipo Likert, cuya confiabilidad alcanzó un alfa de Cronbach de $\alpha = 0.964$. El análisis estadístico, realizado con la prueba t de Student para muestras relacionadas, mostró una mejora significativa en el puntaje promedio de los estudiantes, que pasó de $M_{pre} = 10.50$ ($DE = 1.68$) a $M_{post} = 13.75$ ($DE = 1.91$). Asimismo, se obtuvo una diferencia estadísticamente significativa, ($t(149) = 41.64, p < 0.001$), y un tamaño del efecto muy grande ($d_z = 3.47$). Se observó que la estrategia didáctica mediada por IA contribuyó de manera significativa al aprendizaje de Matemática Discreta, al fortalecer el razonamiento formal requerido en la formación de los estudiantes de Ciencia de Datos.

Palabras clave: inteligencia artificial, estrategia didáctica, matemática discreta, aprendizaje, Ciencia de Datos.

ABSTRACT

The objective of the study was to determine the effect of an artificial intelligence (AI)-mediated teaching strategy on the learning of discrete mathematics among first-year data science students at a university in Lima in 2026. The study was applied in nature, with a quantitative approach and a single-group pre-experimental design involving pre- and post-tests. The population consisted of 150 students, and the sample, selected using a census sampling method, included the entire accessible population ($n = 150$). The intervention consisted of applying a Prompt Engineering protocol as cognitive scaffolding for content in propositional logic, relations, and graph theory. Data collection utilized a knowledge test validated by expert judgment and a Likert-type perception questionnaire, whose reliability achieved a Cronbach's alpha of $\alpha = 0.964$. The statistical analysis, performed using Student's t -test for paired samples, showed a significant improvement in the students' average score, which increased from $M_{pre} = 10.50$ ($DE = 1.68$) a $M_{post} = 13.75$ ($DE = 1.91$). Likewise, a statistically significant difference was obtained ($t(149) = 41.64, p < 0.001$), and a very large effect size ($d_z = 3.47$). It was concluded that the AI-mediated teaching strategy significantly contributed to the learning of discrete mathematics by strengthening the formal reasoning required in the training of data science students.

Keywords: artificial intelligence, teaching strategy, discrete mathematics, learning, data science

ÍNDICE

Dedicatoria	i
Agradecimientos	ii
Resumen	iii
Abstract	iv
Índice de tablas.....	vii
Índice de figuras.....	viii
CAPÍTULO I. INTRODUCCIÓN.....	1
1.1 Planteamiento del Problema.....	1
1.2 Problema de la Investigación	5
1.3 Objetivos de la investigación.....	6
1.4 Justificación de la investigación	7
CAPÍTULO II. MARCO TEORICO	14
2.1 Antecedentes de la investigación.....	14
2.2 Bases Teóricas	23
CAPÍTULO III. METODOLOGIA	38

3.1 Diseño metodológico	38
3.2 Diseño muestral	48
3.3 Procesamiento de datos	50
3.4 Aspectos éticos	51
3.5 Tratamiento estadístico	52
CAPÍTULO IV. RESULTADO.....	55
CAPÍTULO V. DISCUSIÓN	69
CAPÍTULO VI. CONCLUSIONES.....	75
CAPÍTULO VII. RECOMENDACIONES.....	78
Referencia.....	80
Anexo.....	84

ÍNDICE DE TABLAS

Tabla 1	Protocolo de ingeniería de prompts para el aprendizaje de Matemática Discreta.....	13
Tabla 2	Resumen de antecedentes internacionales y nacionales relevantes.....	22
Tabla 3	Dimensiones de la estrategia didáctica mediada por inteligencia artificial.....	32
Tabla 4	Confiabilidad de la prueba de conocimientos de Matemática Discreta.....	42
Tabla 5	Indicadores de equivalencia entre las formas pretest y posttest.....	42
Tabla 6	Organización general de la estrategia didáctica implementada.....	47
Tabla 7	Muestra del estudio según criterio censal.....	50
Tabla 8	Criterios para la contrastación de la hipótesis general.....	53
Tabla 9	Validación del instrumento por juicio de expertos.....	55
Tabla 10	Valores de los niveles de validez según UDEA.....	56
Tabla 11	Estadísticos descriptivos de los puntajes de pretest y posttest.....	57
Tabla 12	Resultados descriptivos del aprendizaje según dimensiones.....	60
Tabla 13	Prueba de normalidad – Kolmogorov-Smirnov de los puntajes globales de pretest y posttest.....	64
Tabla 14	Contrastación de la hipótesis general.....	68

ÍNDICE DE FIGURAS

Figura 1	Modelo TPACK: disposición de los tres tipos de conocimiento básicos y las intersecciones correspondientes, generando, así, siete tipos de conocimiento.....	24
Figura 2	Ecosistema de Aprendizaje Adaptivo.....	33
Figura 3	Esquema del diseño preexperimental de un solo grupo con medición pretest y posttest.....	40
Figura 4	Comparación de puntajes promedio entre pretest y posttest.....	54
Figura 5	Distribución de las diferencias entre posttest y pretest.....	55
Figura 6	Comparación de puntajes promedio por dimensiones del aprendizaje en el pretest y posttest.....	57
Figura 7	Histograma de las diferencias entre los puntajes del posttest y pretest.....	61
Figura 8	Gráfico Q-Q de las diferencias entre los puntajes del posttest y pretest.....	62

Capítulo I – Introducción

1.1. Planteamiento del Problema

La formación universitaria en Ciencia de Datos demanda que los estudiantes desarrollen capacidades de razonamiento formal para analizar información, modelar situaciones y resolver problemas mediante procedimientos verificables.

En este contexto, Matemática Discreta cumple un papel clave, ya que aborda contenidos como lógica proposicional, relaciones, grafos y combinatoria, los cuales resultan fundamentales para asignaturas posteriores vinculadas con algoritmos, programación y estructuras de datos.

La transición hacia el pensamiento discreto suele verse obstaculizada por la demanda de abstracción y la multiplicidad de sus representaciones. Esta realidad educativa exige enfoques que no solo presenten el formalismo matemático, sino que modelen activamente los procesos de razonamiento y argumentación necesarios para navegar con éxito en esta área (Sandefur et al., 2022).

Los hallazgos preliminares en la universidad analizada revelan una situación académica que requiere atención: cerca del 60% de los estudiantes no alcanzan calificaciones satisfactorias en las evaluaciones iniciales. Este resultado expresa dificultades cognitivas frente a los contenidos lógicos, lo que debilita la base conceptual necesaria para unidades de mayor exigencia lógica y computacional.

Esta dificultad de aprendizaje muestra la necesidad de fortalecer los métodos tradicionales mediante estrategias didácticas que garanticen una práctica guiada y una retroalimentación oportuna (Sandefur et al., 2022). En este escenario, la tecnología no aparece como un recurso accesorio, sino como un apoyo pertinente para gestionar la complejidad del pensamiento formal.

A nivel internacional, autores como Trouche (2025) sostienen que la IA generativa ha generado cambios relevantes en la concepción de los currículos, donde la matemática discreta debe ocupar un lugar central para permitir al estudiante anticipar y controlar los efectos de la tecnología sobre la construcción del conocimiento. Desde esta idea, la incorporación de modelos generativos en el aula busca convertir el error recurrente en una oportunidad de autogestión del aprendizaje mediante interacción guiada.

Sin embargo, persiste una limitación pedagógica relevante; como plantean Lepage et al. (2026), la carencia de modelos que definan los "conocimientos básicos" informáticos previos al uso de la IA dificulta que los alumnos de carreras analíticas logren una comprensión profunda de su funcionamiento, derivando muchas veces en un uso superficial.

El uso de IA en educación superior se ha expandido aceleradamente en funciones de soporte al aprendizaje, evaluación y acompañamiento. Una revisión amplia del campo destaca que su aporte educativo depende de la articulación con el diseño pedagógico, los objetivos formativos y la evaluación del aprendizaje (Crompton & Burke, 2023).

En este contexto, cobran importancia los sistemas conversacionales y chatbots educativos; no obstante, se reportan limitaciones y riesgos cuando no existen propósitos pedagógicos claros, criterios de interacción definidos y mecanismos de evaluación consistentes (Kuhail et al., 2023).

Además, se ha observado que los *chatbots* pueden apoyar componentes del aprendizaje autorregulado, pero brindan apoyo limitado en planificación y reflexión profunda, lo que confirma la necesidad de una estrategia didáctica estructurada y no un uso espontáneo de la herramienta (Guan et al., 2025).

Desde esta perspectiva, la incorporación de la IA en el aula no debe entenderse como una automatización de la resolución de problemas, sino como un apoyo guiado mediante la interacción con la IA. Bajo esta perspectiva, la mediación didáctica adopta una forma de interacción guiada en la que la tecnología acompaña al estudiante mediante la fragmentación de problemas complejos y la exigencia de justificaciones formales.

Esta diferencia resulta importante: mientras el uso libre de la IA puede fomentar la pasividad cognitiva, una estrategia mediada por *prompts* estructurados permite que el control del aprendizaje permanezca en el estudiante, bajo una secuencia pedagógica planificada por el docente.

En relación con políticas y criterios de implementación, organismos internacionales han advertido que la incorporación de IA en educación debe orientarse por principios de calidad, equidad y transparencia para maximizar beneficios y reducir riesgos (UNESCO, 2021).

En coherencia con ello, la Comisión Europea propone una visión de educación digital de alta calidad e inclusiva, enfatizando la necesidad de adoptar tecnologías mediante planificación, evaluación y mejora continua, más que por uso instrumental (European Commission, 2020).

En el contexto peruano, el fortalecimiento de resultados formativos y la mejora de la calidad universitaria constituyen retos vigentes, lo que hace pertinente evaluar intervenciones didácticas con evidencia empírica en cursos clave de los primeros ciclos (SUNEDU, 2025).

En correspondencia con esta realidad, en una universidad limeña —cuya identidad se mantiene en reserva por criterios de confidencialidad institucional—, el diagnóstico de la situación académica se sustentó en información recogida en la

propia investigación. Por ello, el nivel inicial de aprendizaje se estableció mediante la aplicación de una prueba diagnóstica (pretest) alineada con los contenidos del curso, lo que permitió describir de manera objetiva el punto de partida del grupo. Posteriormente, tras la implementación de la estrategia didáctica mediada por IA durante cuatro semanas, se aplicó una prueba equivalente (postest). Los resultados cuantitativos y el análisis inferencial correspondiente se presentan en el Capítulo IV.

Pese a la expansión internacional de la IA educativa, persiste la necesidad de contar con evidencia empírica contextualizada que evalúe el efecto de estrategias en cursos con exigencias particulares de razonamiento formal. El problema no se limita al acceso a la tecnología; también involucra su planificación y evaluación pedagógica: se requiere determinar si una estrategia planificada logra mejoras verificables en el aprendizaje en una población concreta de estudiantes de Ciencia de Datos. De este modo, la presente investigación se orientó a determinar el efecto de la estrategia mediante evidencia comparativa pretest–postest.

Además, la investigación delimitó el análisis del aprendizaje a los ejes de lógica proposicional, relaciones (y su representación mediante matriz y grafo dirigido) y teoría de grafos, por corresponder a las unidades desarrolladas durante el periodo de intervención. Dado el diseño preexperimental de un solo grupo, el efecto se estimó a partir del cambio entre las mediciones pretest y postest, reconociendo las limitaciones propias de este tipo de diseño para la inferencia causal.

Desde este enfoque, la variable independiente, denominada “Estrategia didáctica mediada por Inteligencia Artificial Generativa”, consistió en una intervención de interacción guiada de cuatro semanas de duración. Este procedimiento instruccional se articuló mediante sesiones de aprendizaje basadas en un protocolo de ingeniería de *prompts* diseñado bajo los componentes de *System Role*, Instrucción

Obligatoria y Mecanismo de Control. La implementación de dicha estrategia se verificó mediante el registro de interacciones en el *chatbot* educativo y el cumplimiento de guías de práctica, mientras que su impacto en el aprendizaje se contrastó a través de la mejora observada entre los puntajes de la evaluación diagnóstica (pretest) y la evaluación de salida (postest).

1.2. Problemas de investigación

En la formación inicial de los estudiantes de Ciencia de Datos, el curso de Matemática Discreta constituye una base fundamental para el desarrollo posterior de competencias vinculadas con algoritmia, estructuras de datos, lógica formal y modelamiento computacional. Sin embargo, su aprendizaje suele presentar dificultades asociadas al nivel de abstracción de los contenidos, a la necesidad de formalización rigurosa y a la limitada comprensión de estructuras como proposiciones lógicas, relaciones y grafos.

A ello se suma que el uso no guiado de herramientas de inteligencia artificial generativa no garantiza por sí mismo una mejora en el aprendizaje, ya que, en ausencia de criterios pedagógicos claros, puede favorecer respuestas automáticas, dependencia tecnológica o una comprensión superficial de los procedimientos. En ese contexto, surge la necesidad de implementar estrategias didácticas que integren la inteligencia artificial como recurso de mediación, mediante *prompts* estructurados y supervisión docente, con el fin de favorecer el razonamiento formal y el aprendizaje significativo en Matemática Discreta.

Esta necesidad se vuelve más evidente en asignaturas que exigen interpretar relaciones lógicas, justificar procedimientos y verificar resultados con precisión, ya que en estos casos el estudiante no solo debe llegar a una respuesta, sino comprender el camino seguido para construirla. Por ello, la incorporación de la IA en

el aula requiere una orientación didáctica que evite el uso mecánico de la herramienta y promueva una interacción centrada en el análisis, la argumentación y la corrección progresiva de errores. Desde esta perspectiva, la mediación docente continúa siendo decisiva, pues es la que permite que la tecnología se articule con los objetivos formativos del curso y contribuya de manera real al aprendizaje.

En ese marco, la presente investigación planteó las siguientes interrogantes:

1.2.1. *Pregunta General*

¿Cuál es el efecto de una estrategia didáctica mediada por inteligencia artificial en el aprendizaje de Matemática Discreta en estudiantes de Ciencia de Datos de una universidad limeña, 2026?

1.2.2. *Preguntas Específicas*

¿Qué efecto produce la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de lógica proposicional en estudiantes de Ciencia de Datos de una universidad limeña, 2026?

¿Qué efecto produce la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de relaciones y su representación mediante matriz y grafo dirigido en estudiantes de Ciencia de Datos de una universidad limeña, 2026?

¿Qué efecto produce la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de teoría de grafos en estudiantes de Ciencia de Datos de una universidad limeña, 2026?

1.3. Objetivos de Investigación

1.3.1. *Objetivo General*

Determinar el efecto de una estrategia didáctica mediada por inteligencia artificial en el aprendizaje de Matemática Discreta en estudiantes de Ciencia de Datos de una universidad limeña, 2026.

1.3.2. Objetivos Específicos

Determinar el efecto de la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de lógica proposicional en estudiantes de Ciencia de Datos de una universidad limeña, 2026.

Determinar el efecto de la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de relaciones y su representación mediante matriz y grafo dirigido en estudiantes de Ciencia de Datos de una universidad limeña, 2026.

Determinar el efecto de la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de teoría de grafos en estudiantes de Ciencia de Datos de una universidad limeña, 2026.

1.4. Hipótesis de Investigación

1.4.1. Hipótesis General

- La estrategia didáctica mediada por inteligencia artificial se asocia significativamente con el aprendizaje de Matemática Discreta en estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, Lima, 2026.

1.4.2. Hipótesis Específicas

- La estrategia didáctica mediada por inteligencia artificial se asocia significativamente con el aprendizaje de lógica proposicional en estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, Lima, 2026.
- La estrategia didáctica mediada por inteligencia artificial se asocia significativamente con el aprendizaje de relaciones y su representación mediante matriz y grafo dirigido en estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, Lima, 2026.

- La estrategia didáctica mediada por inteligencia artificial se asocia significativamente con el aprendizaje de teoría de grafos en estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, Lima, 2026.

1.5. Justificación de la Investigación

1.5.1. Justificación Teórica

La investigación encuentra sustento teórico en que aborda el aprendizaje de la Matemática Discreta como base del razonamiento formal en la carrera de Ciencia de Datos. La literatura especializada enfatiza que el dominio de contenidos discretos implica desafíos cognitivos vinculados a la abstracción, el tránsito entre representaciones y la comprensión estructural de objetos matemáticos (Sandefur et al., 2022; Li & Zhong, 2026). En esta línea, Trouche (2025) sostiene que, ante el avance de la inteligencia artificial generativa, es imperativo fortalecer los currículos de matemática discreta para que el estudiante desarrolle la capacidad de anticipar, auditar y controlar críticamente el conocimiento generado por sistemas automatizados.

Además, la investigación se sustenta en la evolución de la IA educativa, cuyos beneficios en el acompañamiento y la retroalimentación dependen de su articulación con un diseño pedagógico y objetivos formativos claros (Crompton & Burke, 2023; Chen et al., 2023). En particular, se ha sistematizado que la IA puede favorecer la enseñanza matemática cuando se integra con tareas evaluables y acompañamiento docente (Nanda & Pradhan, 2025; Rivas-Díaz et al., 2024). Al respecto, Lepage et al. (2026) sostienen que la verdadera “alfabetización en IA” nace de la comprensión de sus fundamentos lógicos, lo que refuerza el enfoque de esta investigación al proponer una mediación tecnológica que no se limita a lo instrumental, sino que también se vincula con la comprensión del conocimiento.

Finalmente, la integración de estrategias como la práctica de recuperación (*retrieval practice*) y la modelación digital refuerza el sustento teórico de la intervención, favoreciendo un aprendizaje activo y susceptible de ser contrastado (Muzsnay, 2025; Quarder et al., 2025). De este modo, el estudio contribuye al campo educativo al proponer un modelo donde la tecnología actúa como apoyo guiado para la argumentación y la validación formal, en línea con las demandas actuales de la educación matemática contemporánea (Dana-Picard, 2023; Vivanco-Galván et al., 2024).

1.5.2. Justificación Metodológica

Desde el plano metodológico, la investigación se sustentó en un enfoque cuantitativo con un diseño preexperimental de un solo grupo con medición pretest–posttest. Este diseño resultó pertinente para estimar el cambio en el aprendizaje tras una intervención aplicada en condiciones reales de aula, especialmente cuando no es viable la aleatorización (Campbell & Stanley, 2015). Si bien se reconocen las amenazas intrínsecas a la validez interna de estos diseños, la comparación del desempeño del mismo grupo antes y después de la mediación con IA proporcionó evidencia directa sobre el cambio observado en un entorno educativo natural.

A ello se añade que este diseño permitió seguir una secuencia de medición coherente con el objetivo central de la investigación, ya que hizo posible identificar el nivel inicial de los estudiantes, desarrollar la intervención y contrastar posteriormente los cambios producidos. En ese sentido, su elección respondió a la necesidad de valorar de manera objetiva el efecto de una estrategia didáctica aplicada en una situación educativa concreta.

Asimismo, la investigación empleó instrumentos elaborados para medir con precisión las variables de estudio, como una prueba de conocimientos para evaluar

el aprendizaje y una rúbrica para la resolución de problemas lógicos. Este rigor metodológico cumplió con criterios de validez de contenido por juicio de expertos y confiabilidad por consistencia interna, lo que permitió obtener resultados consistentes y metodológicamente sustentados (Hernández-Sampieri & Mendoza, 2018; Creswell & Creswell, 2023). Además, el análisis inferencial, junto con el cálculo del tamaño del efecto (d de Cohen), permitió interpretar no solo la significancia estadística, sino también la relevancia práctica de la intervención en la población universitaria.

De esta manera, la metodología adoptada no solo permitió verificar si existieron diferencias entre el pretest y el posttest, sino también estimar la magnitud de dichos cambios en términos educativos. Esto fortaleció la solidez del análisis y permitió sustentar las conclusiones a partir de evidencia empírica obtenida en la propia población de estudio.

1.5.3. Justificación Práctica

En el plano práctico, la presente investigación aporta una alternativa didáctica orientada a fortalecer el aprendizaje de Matemática Discreta en la carrera de Ciencia de Datos, considerando que esta asignatura constituye una base importante para el desarrollo de competencias vinculadas con algoritmia, criptografía, estructuras de datos y resolución formal de problemas. Su relevancia práctica se entiende mejor al observar que los contenidos del curso exigen no solo memorización de conceptos, sino también capacidad de análisis, argumentación, verificación y uso riguroso de procedimientos. En ese escenario, las dificultades de los estudiantes no se reducen al dominio de fórmulas o definiciones, sino que alcanzan la comprensión misma de la lógica que sostiene cada proceso de resolución.

A partir de esta situación, la propuesta cobra valor porque atiende una necesidad concreta del contexto formativo: mejorar la comprensión de contenidos que

suelen generar dificultad en los primeros ciclos universitarios y, al mismo tiempo, contribuir al desempeño académico en una asignatura que tiene carácter formativo dentro de la carrera. En lugar de incorporar la inteligencia artificial como un recurso aislado o complementario, la investigación planteó una intervención pedagógica organizada, con una secuencia de interacción diseñada para acompañar el razonamiento del estudiante. Esto permitió que la herramienta no se utilizara como mecanismo de respuesta inmediata, sino como apoyo para analizar, justificar, corregir y reconstruir procedimientos de manera progresiva.

La utilidad práctica de la propuesta radica, precisamente, en que la inteligencia artificial no fue empleada de manera libre o improvisada, sino mediante *prompts* estructurados con intencionalidad pedagógica. Bajo este enfoque, cada interacción buscó mantener al estudiante activo frente al problema, promoviendo que identifique errores, revise supuestos, justifique pasos y contraste sus respuestas con criterios de validez formal. De esta manera, la herramienta pasó a cumplir una función de apoyo al razonamiento, mientras el docente conservó el control pedagógico del proceso, orientando la actividad, supervisando la pertinencia de las respuestas generadas y asegurando que la tecnología se integrara al aprendizaje sin sustituir la reflexión crítica del estudiante.

Otro aspecto que refuerza su valor práctico es que la propuesta ofrece una vía concreta para incorporar la inteligencia artificial en el aula universitaria sin perder la intencionalidad didáctica. En términos aplicados, esto significa que el docente cuenta con una estrategia que puede adaptar a sesiones de aprendizaje centradas en lógica proposicional, relaciones y teoría de grafos, organizando la interacción con la IA en función de propósitos formativos claramente definidos. Así, la tecnología deja de ser un recurso usado de manera espontánea y pasa a formar parte de una experiencia

de aprendizaje guiada, con criterios de seguimiento, objetivos explícitos y una secuencia de apoyo coherente con las exigencias del curso.

Asimismo, la propuesta tiene utilidad para la práctica docente porque favorece condiciones que suelen ser difíciles de sostener de manera permanente en el trabajo de aula, como la retroalimentación inmediata, la revisión paso a paso de procedimientos y la detección oportuna de errores de razonamiento. En cursos como Matemática Discreta, donde los estudiantes deben argumentar, representar relaciones, interpretar estructuras y validar soluciones, este tipo de acompañamiento resulta especialmente valioso. En ese sentido, la mediación con inteligencia artificial permitió reforzar la participación del estudiante, promover una actitud más reflexiva frente al error y fortalecer gradualmente su autonomía para resolver problemas con mayor seguridad y fundamento.

Desde una perspectiva institucional, la propuesta también resulta pertinente porque muestra una forma organizada y viable de integrar tecnologías emergentes en cursos de base, sin desvincularlas de los objetivos de aprendizaje ni del rol formativo del docente. Su aplicación ofrece evidencia útil para pensar en estrategias replicables en asignaturas con alta exigencia lógica, especialmente en contextos donde se requiere mejorar el rendimiento académico y, al mismo tiempo, modernizar las prácticas de enseñanza con criterios pedagógicos claros.

En la siguiente tabla se presenta una síntesis del protocolo de ingeniería de *prompts* aplicado a los principales ejes temáticos del curso, con el propósito de mostrar cómo se organizó la interacción pedagógica con la inteligencia artificial en función de los objetivos de aprendizaje planteados y de las necesidades formativas identificadas en los estudiantes.

Tabla 1

Protocolo de ingeniería de prompts para el aprendizaje de Matemática Discreta

Eje temático	Estructura de interacción pedagógica	Mecanismo de control
Lógica proposicional	Actúa como tutor de lógica formal. Analiza el enunciado: $[X]$. Primero identifica las variables proposicionales, sin aplicar todavía los conectores lógicos. Luego formula una pregunta específica, por ejemplo: “¿Cuál es el conector que relaciona estas dos proposiciones?”. Si la respuesta del estudiante es incorrecta, explica la jerarquía de operadores y orienta la revisión del razonamiento, sin proporcionar la solución final.	Interacción por pasos: impide completar la tabla de verdad hasta que el estudiante demuestre comprensión de la sintaxis lógica y del papel de cada conector.
Relaciones y matrices	Actúa como verificador de propiedades en relaciones. Para la relación R en A : $[X]$, orienta la construcción de la matriz correspondiente sin mostrarla de forma completa. Formula preguntas parciales sobre pares ordenados y su ubicación en la matriz, de modo que el estudiante justifique cada valor antes de registrarlo. Si se detecta un error, solicita revisar la relación entre el par ordenado (a', b) y la posición que ocupa en la matriz.	Validación bit a bit: obliga al estudiante a vincular cada par ordenado con su representación matricial antes de continuar con la resolución.
Teoría de grafos	Actúa como guía para el análisis de grafos. A partir de una matriz o representación dada: $[X]$, orienta al estudiante para identificar propiedades del grafo, describir caminos posibles y verificar la existencia de ciclos, sin adelantar la respuesta. Si el estudiante incurre en un error de interpretación, solicita revisar el grado de entrada o salida de los nodos implicados y justificar el procedimiento seguido.	Razonamiento crítico: evita el uso automático de representaciones gráficas y promueve la interpretación textual, estructural y argumentada del grafo.

Nota: Elaboración propia.

Como puede observarse, la propuesta posee una utilidad práctica clara, pues ofrece una forma organizada y aplicable en contextos similares para incorporar la IA en la enseñanza de la Matemática Discreta. Los prompts fueron diseñados para orientar la interacción con la inteligencia artificial hacia procesos de identificación, verificación, justificación y corrección progresiva, evitando respuestas automáticas y favoreciendo la participación activa del estudiante bajo supervisión docente.

Capítulo II – Marco Teórico

2.1. Antecedentes de la Investigación

2.1.1. *Antecedentes Internacionales*

Los antecedentes internacionales no se incorporan aquí como una sucesión decorativa de autores, sino como un campo de debate que permite delimitar con mayor precisión el problema de esta investigación. La discusión actual ya no gira únicamente en torno a si la IA puede ingresar al aula, sino a bajo qué condiciones su incorporación evita trivializar el aprendizaje y, por el contrario, fortalece procesos de razonamiento formal. Desde esa perspectiva, la Matemática Discreta deja de ser un contenido periférico y pasa a ocupar una posición estratégica en la formación del futuro científico de datos.

Trouche (2025), desde la Universidad de Montpellier, examina una tensión de fondo que esta tesis no puede ignorar: la irrupción de la IA generativa altera el medio didáctico, pero no garantiza, por sí sola, una transformación real del saber enseñado. Su planteamiento resulta valioso porque advierte que no basta con incorporar tecnología; si el paradigma pedagógico permanece intacto, el cambio puede ser solo aparente. En este sentido, el autor señala que la modificación de los entornos didácticos tiende a analizarse principalmente por sus efectos sobre el conocimiento mismo y advierte que es probable que nuevos contenidos curriculares, incluyendo una mayor presencia de la Matemática Discreta, terminen implementándose dentro de paradigmas didácticos esencialmente inalterados.

Lo más importante de este antecedente no es solo la alusión a las matemáticas discretas, sino la advertencia que subyace en ella. Trouche desmonta la idea de que el simple ingreso de herramientas inteligentes equivale a innovación pedagógica. Esa observación dialoga directamente con esta tesis: una estrategia didáctica mediada

por IA solo tiene sentido si obliga a reconfigurar la forma en que el estudiante analiza, justifica, contrasta y valida resultados. De otro modo, la IA corre el riesgo de reforzar prácticas tradicionales bajo una apariencia de modernización.

Lepage, Roy y Romero (2026) desplazan la discusión hacia un punto aún más delicado: los saberes que deben sostener la enseñanza de la IA. Su aporte no se agota en describir experiencias; más bien, interroga la superficialidad con la que muchas veces se introduce esta tecnología en contextos formativos. Los autores plantean que resulta necesario complementar el aprendizaje de los usos de la IA con conocimientos fundamentales sobre sus bases informáticas y advierten que la ausencia de marcos didácticos consolidados dificulta la definición de objetivos formativos claros para los estudiantes (Lepage et al., 2026, pp. 2–3).

Este planteamiento fortalece de manera directa la postura de la presente investigación. Si la comprensión de la IA exige bases previas, entonces la Matemática Discreta no puede tratarse como un saber accesorio. Por el contrario, aporta los fundamentos lógicos, relacionales y estructurales que permiten al estudiante de Ciencia de Datos ir más allá del uso instrumental del software. Bajo esta lógica, la mediación con IA que propone esta tesis no busca deslumbrar al estudiante con respuestas rápidas, sino llevarlo a comprender, cuestionar y verificar la coherencia de los resultados producidos por dichas herramientas.

Martínez et al. (2024), en el contexto mexicano, se concentran específicamente en el aprendizaje de Matemática Discreta con apoyo de IA. Su aporte resulta útil porque evita una lectura ingenuamente optimista. Los autores reconocen que la IA puede elevar la motivación y mejorar el rendimiento; sin embargo, introducen una advertencia que esta tesis considera central: "es responsabilidad del docente supervisar y retroalimentar el resultado de tareas y de las investigaciones, ya que

deben estar realizadas con la ética profesional" (Martínez et al., 2024, p. 9743). Esa observación no es menor. En entornos académicos de alta exigencia analítica, como la formación en Ciencia de Datos, la IA no puede operar como sustituto del pensamiento formal. Su valor pedagógico aparece solo cuando existe una supervisión docente capaz de exigir consistencia lógica, control ético y validación rigurosa de los procedimientos.

Marques y Sant'Ana (2024), desde Brasil, profundizan esta discusión al evidenciar que los asistentes basados en inteligencia artificial no solo ofrecen oportunidades para la enseñanza, sino también limitaciones que pueden afectar la calidad del aprendizaje matemático. A partir de una comparación entre ChatGPT y Gemini en la enseñanza de funciones, los autores identifican dificultades relacionadas con la construcción e interpretación de representaciones gráficas, un aspecto especialmente sensible en disciplinas que demandan precisión formal y rigor conceptual. En este sentido, señalan que los recursos de IA presentan limitaciones en el tratamiento de imágenes y pueden generar errores de construcción e interpretación gráfica. Asimismo, destacan que el docente mantiene un papel fundamental como mediador del proceso educativo, ya que debe evaluar críticamente las posibilidades y limitaciones de las respuestas generadas por estas herramientas.

Este antecedente no confirma una confianza ciega en la IA; más bien, la somete a prueba. Allí radica su valor. Si los modelos pueden producir errores plausibles, entonces la estrategia didáctica no debe orientarse a la aceptación pasiva de sus respuestas, sino al entrenamiento del estudiante para auditarlas críticamente. En el marco de esta tesis, ello cobra especial relevancia, porque aprender Matemática Discreta con mediación de IA exige desarrollar un criterio capaz de distinguir entre una solución formalmente válida y una salida simplemente convincente.

Nanda y Pradhan (2025), a partir de una revisión sistemática internacional, concluyen que la inteligencia artificial favorece el aprendizaje matemático cuando se integra dentro de propuestas pedagógicas estructuradas, con objetivos de aprendizaje definidos, acompañamiento docente y criterios explícitos de evaluación. Asimismo, destacan que los beneficios de la IA dependen de su articulación con el diseño instruccional y no de la tecnología por sí sola.

Chen et al. (2023) refuerzan esta idea al sostener que la mejora del aprendizaje depende de la coherencia entre el recurso tecnológico y el objetivo formativo de la disciplina analítica (p. 112). Holmes et al. (2019), por su parte, advierten que el impacto de la IA no es automático y que su incorporación requiere planificación didáctica para no afectar negativamente la comprensión conceptual (p. 15).

Leídos en conjunto, estos estudios desmontan una idea simplista: la tecnología no mejora por sí misma el aprendizaje. Mejora, sí, pero bajo condiciones didácticas específicas. Esta tesis se alinea con esa posición crítica. No parte del supuesto de que la IA sea beneficiosa en cualquier escenario, sino de la necesidad de examinar cómo una estrategia didáctica estructurada puede convertirla en un recurso cognitivamente productivo dentro del aprendizaje de Matemática Discreta.

Quarder et al. (2025) añaden otra pieza relevante al señalar que los efectos positivos en procesos de modelación aparecen cuando existe alineación entre recursos y actividades académicamente estructuradas (p. 88). Muzsnay (2025), a su vez, destaca el valor de las prácticas de recuperación y de la evaluación formativa para reducir brechas de desempeño en el ámbito universitario (p. 202). Ambos aportes resultan especialmente pertinentes para esta investigación, porque permiten entender que el aprendizaje no se fortalece únicamente por exposición al contenido,

sino por la calidad de las interacciones, retroalimentaciones y decisiones pedagógicas que organizan dicho proceso.

Finalmente, Nanda y Pradhan (2025), a partir de una revisión sistemática de alcance internacional, sostienen que el potencial educativo de la inteligencia artificial no depende únicamente de sus capacidades técnicas, sino de la manera en que es integrada dentro de estrategias pedagógicas planificadas y supervisadas por el docente. Los autores destacan que la IA puede favorecer la personalización del aprendizaje, la retroalimentación oportuna y el desarrollo de competencias matemáticas cuando se articula con objetivos formativos claramente definidos. Este planteamiento resulta particularmente significativo para la presente tesis, ya que coincide con su orientación central: la IA no desplaza al profesor ni reemplaza la exigencia matemática, sino que adquiere valor pedagógico cuando opera dentro de una mediación experta, estructurada y evaluable. En consecuencia, el conjunto de antecedentes examinados no solo respalda la pertinencia de esta investigación, sino que también delimita su aporte específico: analizar el efecto de una estrategia didáctica mediada por IA en el aprendizaje de Matemática Discreta en estudiantes de Ciencia de Datos, asumiendo que dicho efecto depende menos de la herramienta en sí misma que del rigor pedagógico con que se integra al proceso formativo.

2.1.2. Antecedentes Nacionales

El escenario peruano evidencia desafíos significativos en materia de calidad educativa y resultados formativos. El Informe Bienal sobre la Realidad Universitaria Peruana no solo enumera brechas; expone una fractura persistente entre expansión del sistema y solidez de los resultados formativos. Allí está el punto de partida de esta tesis. No basta con hablar de calidad. Hay que producir evidencia concreta, situada, verificable, especialmente en asignaturas donde el razonamiento formal no se

improvisa, como ocurre con la Matemática Discreta en la formación de estudiantes de Ciencia de Datos (Superintendencia Nacional de Educación Superior Universitaria [SUNEDU], 2022).

Contreras y Olaya (2025) entran en ese terreno y lo hacen desde una constatación incómoda: en el sistema universitario peruano, la incorporación de la inteligencia artificial no avanza como una política articulada, sino como un conjunto de esfuerzos dispersos, desiguales y, en no pocos casos, estructuralmente débiles. Su aporte resulta valioso porque no romantiza la innovación. La somete a contraste. Los autores sostienen lo siguiente:

La integración de la inteligencia artificial en la educación superior peruana avanza mediante iniciativas fragmentadas, marcadas por una clara dicotomía entre potencial técnico y barreras estructurales existentes. El proceso siguió rigurosamente las fases del protocolo PRISMA. Se incluyeron 35 trabajos en el estudio: el 74.3% se concentra en Lima, evidenciando centralización. Solo 8.6% indexa en Scopus/WoS, limitando visibilidad internacional. (p. 39).

Este hallazgo adquiere especial relevancia para comprender la situación actual de la investigación sobre inteligencia artificial en la educación superior peruana. Los resultados evidencian que la producción científica en este campo aún presenta limitaciones relacionadas con la concentración territorial de los estudios y su reducida visibilidad internacional. En este contexto, resulta pertinente desarrollar investigaciones que aporten evidencia empírica sobre el efecto de estrategias didácticas mediadas por inteligencia artificial en ámbitos disciplinares específicos. Por ello, la presente investigación analiza el efecto de una estrategia didáctica mediada por inteligencia artificial en el aprendizaje de Matemática Discreta. Asimismo, el

diseño preexperimental se emplea como una estrategia metodológica adecuada para generar evidencia empírica en el contexto educativo estudiado.

Díaz (2025), en una tesis desarrollada en Lima, se aproxima al problema desde un ángulo especialmente útil para este estudio: las tensiones entre utilidad pedagógica y dependencia tecnológica en la enseñanza universitaria de las matemáticas. Su análisis no cae en el entusiasmo automático que suele rodear a la IA generativa. La autora reconoce su potencial para apoyar procesos de personalización y resolución de problemas, sí, pero introduce una advertencia que esta tesis no elude: existe riesgo de uso acrítico y dependencia cuando no median criterios pedagógicos consistentes (p. 40). Este aspecto resulta especialmente relevante para la presente investigación. En ese sentido, se asume que la inteligencia artificial constituye un recurso de apoyo cuyo valor educativo depende de la existencia de objetivos formativos claros, mecanismos de evaluación pertinentes y una mediación pedagógica que favorezca el desarrollo del razonamiento formal y la comprensión de los contenidos.

Rivas-Díaz et al. (2024) refuerzan esta línea, aunque desde una formulación más orientada a la optimización de la enseñanza matemática en educación superior. Su aporte no está en anunciar que la IA personaliza o retroalimenta —eso ya casi se ha vuelto un lugar común—, sino en subrayar que tales beneficios solo se materializan cuando se articulan con prácticas docentes intencionales y con objetivos evaluables. Este aspecto resulta especialmente relevante porque evidencia que la mejora del aprendizaje no depende exclusivamente de la presencia de la tecnología, sino de las condiciones pedagógicas que orientan su utilización y de la coherencia entre los objetivos formativos, las actividades propuestas y los mecanismos de evaluación.

Román Cañizares (2024) examina el rol de la IA en la enseñanza de matemáticas dentro de entornos virtuales y encuentra beneficios ligados a la interacción con el contenido. Ahora bien, el valor de este antecedente no reside solo en registrar ventajas, sino en condicionar su eficacia a la integración de decisiones pedagógicas concretas. Bajo esta lógica de ruptura, la tecnología no enseña por sí misma; amplifica o debilita el aprendizaje según el andamiaje didáctico que la sostenga. En términos generales, la inteligencia artificial puede enriquecer la experiencia formativa; sin embargo, también puede limitar el aprendizaje cuando no existe una adecuada orientación docente que supervise, acompañe y dé sentido pedagógico a su utilización. En conjunto, los antecedentes nacionales coinciden en señalar que la inteligencia artificial no mejora el aprendizaje matemático únicamente por su incorporación al proceso educativo, sino cuando forma parte de una estrategia pedagógica estructurada, evaluable y acompañada por supervisión docente. Asimismo, los estudios revisados evidencian la necesidad de generar mayor evidencia empírica sobre los efectos de estas tecnologías en contextos universitarios específicos. En este marco, la presente investigación analiza el efecto de una estrategia didáctica mediada por inteligencia artificial en el aprendizaje de Matemática Discreta en estudiantes de Ciencia de Datos de una universidad limeña, contribuyendo al fortalecimiento del conocimiento disponible sobre la integración pedagógica de la IA en la educación superior.

En conjunto, los antecedentes nacionales respaldan la pertinencia de la presente investigación y evidencian la necesidad de continuar generando evidencia empírica sobre el uso de la inteligencia artificial en la educación superior. Esta necesidad resulta especialmente relevante en áreas de alta exigencia cognitiva, como

la Matemática Discreta, donde aún existen limitados estudios aplicados en estudiantes de Ciencia de Datos

A continuación, la Tabla 2 presenta un resumen ejecutivo de estos estudios para facilitar su contraste.

Tabla 2

Resumen de antecedentes internacionales y nacionales relevantes

Autor	País	Aporte principal
Trouche (2025)	Francia	Justifica la necesidad de reconfigurar el currículo hacia la Matemática Discreta.
Lepage et al. (2026)	Francia	Define los "saberes fundamentales" para evitar el aprendizaje superficial de la IA
Martínez et al. (2024)	México	Enfatiza el rol docente en la supervisión ética de las soluciones de IA.
Díaz (2025)	Perú	Advierte sobre el uso crítico y la dependencia si no hay criterios pedagógicos.

Nota: Elaboración propia.

La revisión de los antecedentes permite identificar que, si bien existe un creciente interés por la incorporación de la inteligencia artificial en la educación superior, la mayoría de los estudios se ha centrado en analizar su potencial general para apoyar procesos de enseñanza y aprendizaje. Sin embargo, son limitadas las investigaciones que evalúan específicamente su efecto en el aprendizaje de Matemática Discreta, particularmente en estudiantes de Ciencia de Datos, una disciplina que demanda elevados niveles de razonamiento lógico y abstracción. Asimismo, en el contexto peruano se observa una escasa producción de estudios empíricos que analicen, mediante mediciones pretest y posttest, el impacto de estrategias didácticas mediadas por inteligencia artificial generativa en cursos vinculados al razonamiento formal. En ese sentido, la presente investigación aporta evidencia empírica sobre el efecto de una estrategia didáctica mediada por IA en el aprendizaje de lógica proposicional, relaciones y teoría de grafos, contribuyendo a

fortalecer el conocimiento disponible sobre la integración pedagógica de estas tecnologías en la formación universitaria de Ciencia de Datos.

2.2. Bases Teóricas

2.2.1. Estrategia didáctica mediada por inteligencia artificial

2.2.1.1. Definición

Implementar una estrategia didáctica mediada por Inteligencia Artificial (IA) no supone únicamente incorporar una herramienta digital al aula, sino replantear la manera en que se organiza la enseñanza para favorecer aprendizajes específicos. En esta investigación, dicha estrategia se concibe como un conjunto articulado de decisiones pedagógicas, planificadas en función de objetivos formativos concretos, mediante las cuales el docente orienta el proceso de aprendizaje de los estudiantes en Matemática Discreta. Desde esta comprensión, la tecnología no ocupa un lugar accesorio, sino que se integra a la estructura misma de la intervención didáctica.

Este planteamiento se sustenta en el modelo TPACK (Technological Pedagogical Content Knowledge) propuesto por Mishra y Koehler (2006), el cual sostiene que la integración tecnológica resulta pedagógicamente significativa cuando se articula de manera coherente con el conocimiento del contenido y con las decisiones metodológicas del docente. En esa línea, el valor educativo de la IA no reside en su sola presencia dentro del entorno de aprendizaje, sino en la forma en que contribuye a mediar la construcción del conocimiento disciplinar.


En el marco de esta tesis, ello implica vincular la IA con las particularidades de la enseñanza de la Matemática Discreta y con las demandas formativas propias de los estudiantes de Ciencia de Datos. Por esta razón, no se asume la IA como un recurso aislado, sino como un componente de mediación que permite diversificar la presentación de los contenidos, acompañar los procesos de resolución y ofrecer

apoyos ajustados a las dificultades que surgen durante el aprendizaje (ver figura 1). Esta mediación adquiere especial relevancia en un curso caracterizado por altos niveles de abstracción, exigencia lógica y necesidad de representación formal.

Bajo esta perspectiva, la estrategia propuesta no busca sustituir la función pedagógica del docente, sino fortalecer su capacidad de orientación y seguimiento del aprendizaje. La incorporación de IA permite generar un entorno con mayores posibilidades de retroalimentación, acompañamiento y ajuste didáctico, en función del progreso del estudiante. De este modo, se favorece una aproximación más comprensible a los conceptos y procedimientos de la Matemática Discreta, sin renunciar al rigor conceptual que exige la disciplina. En consecuencia, la tecnología se integra como un medio pedagógico orientado al fortalecimiento del pensamiento crítico, la resolución de problemas y la participación activa del estudiante en su propio proceso formativo.

Figura 1

Modelo TPACK: disposición de los tres tipos de conocimiento básicos y las intersecciones correspondientes, generando, así, siete tipos de conocimiento.



Nota: Adaptado de “Technological Pedagogical Content Knowledge: A Framework for Teacher Knowledge”, por P. Mishra y M. J. Koehler, 2006, *Teachers College Record*, 108(6), p. 1017.

En relación con la gestión del esfuerzo mental durante el aprendizaje, Sweller (2020) sostiene lo siguiente:

Este planteamiento resulta pertinente para la enseñanza de la Matemática Discreta, debido a que muchos de sus contenidos exigen atender de manera simultánea definiciones, reglas de inferencia, procedimientos y formas de representación. En ese contexto, la mediación con inteligencia artificial puede contribuir a disminuir parte de la carga extrínseca cuando asume tareas de apoyo vinculadas con la verificación, el seguimiento del procedimiento o la organización inicial de la información. Ello permite que el estudiante concentre mayores recursos cognitivos en la comprensión de relaciones lógicas, estructuras discretas y procesos de resolución. En términos didácticos, esto favorece un trabajo más centrado en la construcción del razonamiento que en la sobrecarga operativa.

2.2.1.2. Teorías que sustentan la estrategia didáctica mediada por IA

La teoría de Gagné plantea que el aprendizaje mejora cuando la enseñanza se organiza mediante eventos instruccionales capaces de generar condiciones externas que activen procesos internos en el estudiante (Gagné, 1965). Desde esta perspectiva, no basta con exponer contenidos; también se requiere ordenar la experiencia de aprendizaje de modo que se capte la atención, se recuperen saberes previos, se oriente la ejecución, se promueva la respuesta del estudiante y se proporcione retroalimentación. Así, la enseñanza deja de entenderse como transmisión de información y pasa a concebirse como una secuencia estructurada de apoyos para favorecer la retención y la transferencia.

Junto con ello, la investigación considera la Teoría del Andamiaje Digital, que traslada al entorno tecnológico el planteamiento clásico del apoyo temporal al aprendizaje. De acuerdo con Luckin (2018), la inteligencia artificial puede actuar como un sistema de acompañamiento dinámico capaz de ajustarse al nivel de desempeño del estudiante dentro de su zona de desarrollo próximo. En Matemática Discreta, este

aporte se expresa en apoyos concretos, como la resolución guiada de ejercicios, la revisión de procedimientos o la verificación de resultados, los cuales pueden ir retirándose progresivamente a medida que el estudiante fortalece su autonomía y consolida sus esquemas de razonamiento.

En una asignatura como Matemática Discreta, donde se exige precisión conceptual, control del procedimiento y argumentación formal, este sustento teórico respalda la organización de la estrategia en fases claramente definidas: diagnóstico, modelamiento, práctica guiada, aplicación y retroalimentación inmediata. En el presente estudio, la inteligencia artificial se incorpora sobre todo en momentos clave del proceso, especialmente en la orientación paso a paso, la práctica recurrente y la identificación de errores. No obstante, su función sigue siendo de mediación y apoyo; no sustituye la conducción pedagógica del docente ni el proceso de evaluación del aprendizaje.

2.2.1.3. Implicancias en el aprendizaje de Matemática Discreta

La estrategia mediada por IA tiene implicancias relevantes en el aprendizaje de Matemática Discreta porque esta asignatura demanda formalización, verificación de procedimientos y tránsito entre diferentes formas de representación, como expresiones lógicas, tablas, matrices y grafos. Estas exigencias suelen generar errores persistentes en los estudiantes, sobre todo cuando aún no consolidan el razonamiento formal. Por ello, disponer de práctica guiada y retroalimentación en momentos oportunos resulta decisivo para afianzar el aprendizaje.

En ese marco, la inteligencia artificial puede aportar al facilitar secuencias rápidas de práctica, detección de error y corrección, además de brindar apoyos durante la resolución de tareas. También permite registrar el progreso del estudiante, información que puede ser útil para orientar decisiones pedagógicas más ajustadas.

Para estudiantes de Ciencia de Datos, esta mediación adquiere un valor adicional, ya que no solo apoya el aprendizaje del curso, sino que también los familiariza con entornos de interacción con sistemas inteligentes.

Desde esta misma línea, autores como Gallier (2020) y Luckin (2018) sostienen que la IA puede favorecer la comprensión de conceptos abstractos cuando se integra a procesos de acompañamiento cognitivo. De forma complementaria, Chen et al. (2020) y Holmes et al. (2019) advierten que su efectividad no depende del uso de la herramienta por sí misma, sino de su articulación con objetivos, actividades y evaluación. En educación matemática, esta precisión es clave, ya que una integración improvisada tiende a debilitar el valor pedagógico de la tecnología. En cambio, cuando existe planificación didáctica, tareas definidas y seguimiento del desempeño, la mediación con IA puede convertirse en un apoyo real para el desarrollo del aprendizaje formal. Esta idea también es consistente con la revisión sistemática reportada Nanda y Pradhan (2025), quienes concluyen que el aporte de la inteligencia artificial resulta más evidente cuando forma parte de propuestas pedagógicas estructuradas, con objetivos de aprendizaje claramente definidos, acompañamiento docente y mecanismos de evaluación coherentes

2.2.1.4. Factores que influyen en la efectividad de la estrategia mediada por IA

La efectividad de una estrategia mediada por IA no depende únicamente de la disponibilidad tecnológica, sino del modo en que esta se inserta en el diseño instruccional y en la práctica pedagógica. Un primer factor es la claridad de los objetivos de aprendizaje y de los criterios de logro, ya que estos orientan el trabajo del estudiante y permiten que la retroalimentación tenga un sentido formativo real (Hattie & Timperley, 2007).

Otro aspecto central es la coherencia entre actividades, recursos y evaluación. Desde el enfoque de alineación constructiva, los resultados de aprendizaje, las tareas propuestas y las evidencias de evaluación deben guardar correspondencia para que el proceso formativo mantenga consistencia interna y permita interpretar con validez los logros alcanzados (Biggs & Tang, 2011). A ello se suma la calidad del feedback. La retroalimentación aporta más al aprendizaje cuando no se reduce a señalar si una respuesta es correcta o incorrecta, sino cuando ayuda al estudiante a comprender el error, identificar el punto de quiebre y reconocer qué debe hacer para mejorar (Hattie & Timperley, 2007).

También es necesario considerar la carga cognitiva implicada en el diseño de las actividades. Cuando las explicaciones son extensas, confusas o están mal organizadas, aumenta la carga extrínseca y disminuye la eficiencia del aprendizaje. Por ello, conviene segmentar la información, graduar ejemplos y focalizar el apoyo en pasos críticos del procedimiento (Sweller et al., 2011). Finalmente, la implementación de estrategias con IA en educación superior debe desarrollarse bajo criterios institucionales y éticos vinculados con transparencia, equidad y protección de datos, tal como recomiendan organismos internacionales como la UNESCO (2022).

2.2.1.5. Aplicación pedagógica de la IA en educación superior

En educación superior, la mediación con IA se manifiesta en funciones como la tutoría, la recomendación de actividades, la retroalimentación automatizada y el seguimiento del aprendizaje. Chen et al. (2020) señalan que estos aportes pueden contribuir a personalizar la enseñanza, siempre que su uso responda a criterios de logro previamente definidos. En la misma línea, Holmes et al. (2019) advierten que el valor pedagógico de la IA no radica en reemplazar el razonamiento del estudiante,

sino en integrarse a prácticas docentes que orienten, acompañen y den sentido al proceso formativo.

2.2.1.6. Criterios para la mediación pedagógica con IA en áreas formales

La literatura especializada coincide en que la efectividad de una estrategia mediada por IA no depende únicamente de la tecnología empleada, sino del modo en que se definen las actividades, las formas de interacción y las evidencias de desempeño. En disciplinas formales como la Matemática Discreta, este aspecto adquiere especial importancia, ya que la práctica guiada y la retroalimentación inmediata cumplen una función reguladora frente al nivel de abstracción que demandan los contenidos.

Al respecto, la revisión sistemática de Nanda y Pradhan (2025) muestra que las herramientas de inteligencia artificial alcanzan mejores resultados pedagógicos cuando se integran en propuestas de enseñanza estructuradas, con objetivos claramente definidos, actividades planificadas y mecanismos de seguimiento del progreso del estudiante. Esta evidencia respalda la necesidad de organizar la mediación tecnológica como un entorno de aprendizaje adaptativo, en el que la IA no se limite a ofrecer respuestas, sino que ajuste el nivel de exigencia según el desempeño observado.

En el caso de la formación en Ciencia de Datos, esta organización permite que la estrategia se traduzca en un entrenamiento orientado al desarrollo de capacidades lógicas verificables. Desde ese marco, el uso de un diseño de evaluación basado en la comparación pretest–posttest encuentra sustento teórico como una vía pertinente para examinar cambios en el desempeño después de la intervención, permitiendo observar la progresión del estudiante con un criterio metodológico claro.

2.2.1.7. Sustentación teórica de la estrategia mediada por IA

Las fuentes seleccionadas para sustentar la estrategia didáctica mediada por IA permiten vincular el diseño instruccional con los aportes contemporáneos de la tecnología educativa. Los planteamientos de Gagné (1965), Reigeluth (1983) y Merrill (2002) ofrecen una base sólida para estructurar intervenciones pedagógicas organizadas, evaluables y orientadas al aprendizaje. Por su parte, Chen et al. (2020) y Holmes et al. (2019) aportan un marco actual para comprender la IA como un recurso de mediación cuyo valor depende de la planificación docente y de su articulación con objetivos formativos concretos. A ello se suma la revisión sistemática de Nanda y Pradhan (2025), que aporta evidencia reciente sobre el uso de la inteligencia artificial en educación matemática y destaca que sus beneficios son más consistentes cuando se integra dentro de propuestas pedagógicas estructuradas, con seguimiento del aprendizaje y acompañamiento docente.

2.2.1.8. Dimensiones de la estrategia mediada por IA

La primera dimensión es la adaptabilidad, entendida como la capacidad de ajustar contenidos, secuencia, dificultad y ritmo de aprendizaje en función del desempeño del estudiante. Esta dimensión se relaciona con el potencial de la inteligencia artificial para sostener trayectorias flexibles y avances progresivos por niveles de dominio cuando se incorpora a tareas evaluables (Holmes et al., 2019; Chen et al., 2020). En educación matemática, su aporte resulta más consistente cuando estos ajustes se integran en propuestas pedagógicas estructuradas que permiten adaptar la enseñanza a las necesidades del estudiante y realizar un seguimiento sistemático de su progreso (Nanda & Pradhan, 2025).

La segunda dimensión es la interactividad, definida como el nivel de participación activa entre estudiante y sistema a través de tutorías, diálogo guiado y

apoyo durante la resolución de ejercicios. Su relevancia radica en que favorece la explicitación de procedimientos y el contraste de argumentos en tareas de carácter formal (Holmes et al., 2019). En el caso de los chatbots educativos, la evidencia revisada indica que su utilidad depende de contar con objetivos instruccionales claros, criterios de interacción bien delimitados y procesos de evaluación consistentes (Kuhail et al., 2023).

La tercera dimensión es la automatización, entendida como la generación de ejercicios, la corrección automática y la retroalimentación inmediata para sostener ciclos continuos de práctica, error y corrección. Su efectividad depende de que el feedback mantenga un carácter formativo y esté vinculado con criterios de logro, evitando reducirse a la entrega mecánica de respuestas (Chen et al., 2020; Hattie & Timperley, 2007). Además, esta dimensión requiere integrarse en una secuencia coherente con los objetivos de aprendizaje y la evaluación planteada (Biggs, 1996; Biggs & Tang, 2011).

La cuarta dimensión es la personalización, definida como el ajuste de trayectorias de aprendizaje según necesidades individuales, errores frecuentes, secuencia de tareas y tipo de apoyo requerido. Esta dimensión exige no solo planificación pedagógica, sino también criterios éticos relacionados con la equidad y la privacidad, tal como señalan los lineamientos internacionales sobre el uso educativo de la IA (UNESCO, 2021; UNESCO, 2023). En educación matemática, su aporte resulta más evidente cuando la inteligencia artificial se integra en propuestas pedagógicas estructuradas que favorecen la diferenciación de la enseñanza, la retroalimentación adaptativa y la atención a las necesidades específicas de los estudiantes (Nanda & Pradhan, 2025).

En conjunto, estas dimensiones configuran una propuesta pedagógica que va más allá del soporte técnico. Su articulación permite estructurar un entorno de aprendizaje adaptativo en el que la tecnología acompaña, regula y fortalece el proceso formativo. Para el estudiante de Ciencia de Datos, esta mediación puede contribuir a reducir parte de la carga operativa vinculada con la verificación procedimental, permitiendo concentrar más esfuerzo en el razonamiento estructural y en la comprensión de problemas lógicos de mayor complejidad.

Con el fin de asegurar el rigor metodológico y la trazabilidad de la medición, se delimitan cuatro dimensiones para la variable independiente. Estas dimensiones recogen aportes coincidentes de la literatura especializada y se operacionalizan en el instrumento de recolección de datos, específicamente en el cuestionario tipo Likert. En la Tabla 3 se presenta la relación entre cada dimensión, su definición y los ítems correspondientes para su evaluación.

Tabla 3

Dimensiones de la estrategia didáctica mediada por inteligencia artificial


Dimensión	Definición	Ítems	Referente teórico
Adaptabilidad	Capacidad de ajustar contenidos, dificultad y ritmo según el desempeño previo y progreso del alumno,	1,2,3,4	Nanda y Pradhan (2025); Holmes et al. (2019)
Interactividad	Nivel de participación y diálogo guiado para la resolución de ejercicios y contraste de ideas formales.	5,6,7,8	Kuhail et. al. (2023) ; Holmes et. al. (2019)
Automatización	Generación de ejercicios de práctica y retroalimentación inmediata para corregir errores en tiempo real.	9,10,11,12	Chen et. al (2023) ; Hattie &Timperley (2007)
Personalización	Ajuste de trayectorias individuales considerando errores frecuentes y necesidades específicas de apoyo.	13,14,15,16	UNESCO (2023); Nanda y Pradhan (2025)

Nota: Elaboración propia.

En síntesis, la articulación de estas dimensiones permite comprender la estrategia como un sistema de mediación pedagógica en el que la tecnología cumple una función formativa concreta. Esta organización se representa en la Figura 2, donde se integran los componentes que orientan la intervención en Matemática Discreta.

Figura 2

Ecosistema de Aprendizaje Adaptivo



Nota: Elaboración propia basada en Nanda y Pradhan (2025); Holmes et al. (2019), Kuhail et al. (2023), Chen et al. (2020), Hattie y Timperley (2007) y UNESCO (2023).

2.2.2. Aprendizaje de Matemática Discreta en estudiantes de Ciencia de Datos

2.2.2.1. Definición y operacionalización de la variable

En esta investigación, el aprendizaje de Matemática Discreta se asume como el logro de desempeños observables y verificables en contenidos y procedimientos vinculados con la lógica proposicional, las relaciones y los grafos. Dichos desempeños se expresan en la capacidad del estudiante para formalizar, justificar y resolver problemas mediante estructuras discretas. En el caso de los estudiantes de Ciencia de Datos, este aprendizaje no cumple una función accesoria; constituye, más

bien, una base formativa para cursos posteriores como algoritmos, estructuras de datos y modelamiento probabilístico. Con ese criterio, la variable se operacionaliza mediante una prueba de conocimientos aplicada en dos momentos, pretest y posttest, ambos alineados con los contenidos desarrollados durante la intervención. De este modo, el aprendizaje se interpreta como una variación medible en el nivel de desempeño del estudiante.

2.2.2.2. Subcontenidos relevantes para el aprendizaje formal

Los contenidos que organizan el aprendizaje del curso comprenden la lógica proposicional, las relaciones junto con su representación mediante matrices y grafos dirigidos y la teoría de grafos. Se trata de temas que exigen precisión conceptual, manejo riguroso de reglas formales y verificación de propiedades. Por ello, el aprendizaje no se reduce a repetir procedimientos, sino que se evidencia en la capacidad para traducir situaciones del lenguaje natural al lenguaje formal, operar con estructuras lógicas y validar resultados de manera consistente. La literatura que vincula la Matemática Discreta con el pensamiento computacional destaca que esta asignatura favorece habilidades de abstracción y construcción de soluciones (Liu & Wang, 2010). Esa relación permite reconocer en el estudiante no solo un avance temático, sino también una progresión académica más nítida en el plano del razonamiento formal.

2.2.2.3. Articulación entre el aprendizaje y el pensamiento computacional

El pensamiento computacional ha sido definido como una forma de resolver problemas y diseñar soluciones a partir de conceptos fundamentales de la computación (Wing, 2006). En el ámbito educativo, este enfoque suele vincularse con procesos como la abstracción, la descomposición y el diseño de procedimientos (Grover & Pea, 2013). Estas nociones guardan una relación directa con la Matemática

Discreta, ya que la asignatura exige representar estructuras complejas, construir argumentos válidos y verificar procedimientos dentro de contextos discretos. Desde esa perspectiva, el aprendizaje del curso puede comprenderse como un fortalecimiento del razonamiento formal que luego resulta necesario para el desempeño lógico-computacional de mayor nivel.

2.2.2.4. Evaluación del aprendizaje mediante el diseño pretest–posttest

En un diseño preexperimental, la evaluación del aprendizaje se realiza comparando el desempeño de los mismos estudiantes antes y después de la intervención pedagógica. El pretest permite establecer el nivel de partida, mientras que el posttest permite observar el cambio producido tras la aplicación de la estrategia. Ahora bien, esta comparación solo resulta válida si ambos instrumentos guardan una alineación estricta con los criterios de logro definidos para la investigación. La coherencia entre objetivos, actividades y evaluación constituye un principio central para interpretar ese cambio como una evidencia válida de aprendizaje (Biggs & Tang, 2011). En tal sentido, este marco se justifica como una vía objetiva para estimar el progreso alcanzado en Matemática Discreta.

2.2.2.5. Sustentación de las fuentes para la variable dependiente

Las fuentes seleccionadas resultan pertinentes porque permiten sostener, desde distintos ángulos, la comprensión teórica de la variable dependiente. Por un lado, respaldan el vínculo entre razonamiento formal y pensamiento computacional como marco de interpretación del aprendizaje (Wing, 2006; Grover & Pea, 2013). Por otro, aportan evidencia específica sobre la Matemática Discreta como un espacio especialmente propicio para el desarrollo del razonamiento lógico, el pensamiento sistemático y la abstracción, competencias fundamentales para la formación en ciencias de la computación y ciencia de datos (Li & Zhong, 2026). A ello se suman

referencias sobre alineación constructiva y evaluación del aprendizaje, necesarias para sustentar la validez de la medición mediante pruebas estandarizadas (Biggs & Tang, 2011). En conjunto, estas contribuciones fortalecen la rigurosidad conceptual de la variable y hacen más sólida su interpretación científica.

2.2.2.6. Dimensiones del aprendizaje en Matemática Discreta

La primera dimensión corresponde a la lógica proposicional. Esta comprende el aprendizaje relacionado con la identificación de proposiciones, el uso de conectores lógicos, la construcción e interpretación de tablas de verdad, el análisis de equivalencias lógicas y la evaluación de la validez de argumentos. Su importancia radica en que fortalece la formalización del razonamiento y la justificación de procedimientos.

La segunda dimensión es relaciones y su representación mediante matriz y grafo dirigido. Aquí se incluye el aprendizaje vinculado con la identificación y análisis de relaciones, sus propiedades y sus distintas formas de representación mediante matrices y grafos dirigidos. Esta dimensión permite que el estudiante transite entre diversas representaciones formales y reconozca estructuras discretas desde una perspectiva analítica y visual.

La tercera dimensión es teoría de grafos. Comprende el aprendizaje asociado con el reconocimiento de vértices, aristas, grados, tipos de grafos y la resolución de problemas básicos mediante representaciones gráficas. Esta dimensión resulta relevante porque favorece la modelación de situaciones discretas y fortalece un tipo de razonamiento estructural especialmente útil en contextos computacionales.

2.2.2.7. Capacidades asociadas al aprendizaje de matemática discreta

Entre las capacidades asociadas al aprendizaje de Matemática Discreta destaca, en primer lugar, el razonamiento lógico, entendido como la habilidad para operar con proposiciones, conectores, cuantificadores y reglas de inferencia, así como para justificar la validez de argumentos en problemas discretos. Esta capacidad se relaciona con el énfasis del pensamiento computacional en soluciones verificables y con la naturaleza formal de la lógica (Wing, 2006).

También resalta la abstracción formal, entendida como la capacidad para reconocer patrones, generalizar estructuras y representar objetos discretos en distintas formas, como lenguaje formal, tablas, matrices y grafos. La abstracción ocupa un lugar central tanto en el pensamiento computacional como en el aprendizaje matemático estructural (Grover & Pea, 2013).

Otra capacidad relevante es el diseño algorítmico, entendido como la formulación de procedimientos finitos y ordenados, la descomposición de problemas y la construcción de soluciones paso a paso con verificación. Esta capacidad se vincula con el pensamiento computacional en la medida en que exige organizar soluciones procedimentales de manera lógica y secuencial (Wing, 2006).

Finalmente, se considera la resolución computacional de problemas, definida como la capacidad para modelar, resolver y validar problemas mediante estructuras discretas, transfiriendo procedimientos a situaciones nuevas. Esta capacidad integra modelamiento y construcción de soluciones, dos componentes especialmente valiosos en el entrenamiento del pensamiento computacional dentro de la Matemática Discreta (Liu & Wang, 2010).

Capítulo III – Metodología

3.1. Diseño Metodológico

3.1.1. *Tipo de Investigación*

La investigación fue de tipo aplicada, ya que se orientó a atender una necesidad concreta del proceso de enseñanza-aprendizaje en el contexto universitario. En este caso, el interés del estudio estuvo centrado en analizar cómo una estrategia didáctica mediada por inteligencia artificial podía contribuir al aprendizaje de Matemática Discreta en estudiantes del primer ciclo de Ciencia de Datos.

Desde esta perspectiva, no se trató únicamente de describir una situación educativa, sino de intervenir sobre ella y valorar los cambios observados a partir de una propuesta pedagógica implementada en el aula. Por ello, el estudio mantiene un sentido práctico y formativo, en tanto busca generar evidencia útil para experiencias de enseñanza similares.

3.1.2. *Enfoque de Investigación*

La investigación se desarrolló bajo un enfoque cuantitativo, dado que implicó la recolección y análisis de datos numéricos con la finalidad de contrastar hipótesis y estimar el cambio en el aprendizaje antes y después de la intervención. Este enfoque se caracteriza por el uso de instrumentos estructurados, mediciones objetivas y procedimientos estadísticos que permiten interpretar los resultados con criterios de validez y confiabilidad (Hernández-Sampieri & Mendoza, 2018; Creswell & Creswell, 2023).

Para el procesamiento de la información se empleó el entorno de computación en la nube Google Colab, utilizando el lenguaje de programación Python. Asimismo, se recurrió a librerías como Pandas, Matplotlib y Seaborn para la organización y

depuración de la matriz de datos, así como para la elaboración de visualizaciones que complementaron el análisis de los resultado

3.1.3. Alcance de Investigación

El alcance es explicativo en el marco del diseño preexperimental, dado que se busca estimar el efecto de la intervención a partir del cambio observado entre mediciones pretest y posttest en el mismo grupo. Este alcance permite evaluar la variación asociada a la aplicación de la estrategia, reconociendo que, al no contar con grupo control ni aleatorización, la inferencia causal es limitada (Campbell & Stanley, 2015; Hernández-Sampieri & Mendoza, 2018). En consecuencia, los hallazgos se interpretan como evidencia de mejora dentro del alcance del diseño empleado.


3.1.4. Diseño de Investigación

El diseño de investigación correspondió a un preexperimental de un solo grupo con medición pretest-posttest. Este diseño permite observar la variación del mismo grupo antes y después de la intervención, y resulta pertinente cuando las condiciones del estudio no permiten trabajar con grupos equivalentes ni aplicar procedimientos de aleatorización (Campbell & Stanley, 2015).

Su representación fue G1 O1 X O2, donde G1 identifica al grupo único de estudio, O1 a la medición inicial o pretest, X a la intervención basada en una estrategia didáctica mediada por inteligencia artificial desarrollada durante cuatro semanas, y O2 a la medición final o posttest. A partir de este esquema, el efecto de la intervención se estimó mediante la diferencia observada entre ambas mediciones ($\Delta = O2 - O1$). Dicha diferencia fue analizada mediante la prueba t de Student para muestras relacionadas, con el propósito de determinar si el cambio registrado era estadísticamente significativo.

Figura 3

Esquema del diseño preexperimental de un solo grupo con medición pretest y posttest



Nota: Elaboración propia.

Donde:

G1: Grupo único de estudiantes

O1: Medición inicial (pretest)

X: Intervención (estrategia didáctica mediada por IA)

O2: Medición final (posttest)

Δ : Cambio observado (O2-O1)

3.1.5. Técnica

Para la recolección de datos se emplearon dos técnicas: la evaluación y la encuesta. La evaluación se aplicó mediante una prueba de conocimientos, con el propósito de medir el aprendizaje de Matemática Discreta en dos momentos del estudio: antes de la intervención (pretest) y después de ella (posttest). Por su parte, la encuesta se desarrolló a través de un cuestionario tipo Likert, orientado a describir la percepción y el uso de la estrategia didáctica mediada por inteligencia artificial durante la intervención. En conjunto, ambas técnicas permitieron obtener información cuantificable y comparable para el análisis estadístico (Hernández-Sampieri & Mendoza, 2018; Creswell & Creswell, 2023).

3.1.6. Instrumentos

Se emplearon dos instrumentos de recolección de datos. El primero fue una prueba de conocimientos de Matemática Discreta, aplicada en dos momentos del estudio, como pretest y posttest, con el fin de valorar el aprendizaje de los estudiantes

antes y después de la intervención. El segundo fue un cuestionario tipo Likert, diseñado para recoger información sobre la estrategia didáctica mediada por inteligencia artificial.

La prueba de conocimientos estuvo conformada por 12 ítems, distribuidos en las dimensiones de lógica proposicional, relaciones y teoría de grafos. Su calificación se efectuó mediante una rúbrica analítica con puntajes de 0 a 2 por ítem, por lo que el puntaje máximo alcanzable fue de 24 puntos. El cuestionario, por su parte, estuvo integrado por 12 ítems, organizados en las dimensiones de adaptabilidad, interactividad, automatización y personalización, con cinco alternativas de respuesta en escala Likert.

Para establecer la validez de contenido, ambos instrumentos fueron sometidos a juicio de expertos. La revisión consideró criterios como relevancia, claridad y precisión, coherencia, organización, consistencia, marco de referencia, extensión e inocuidad. Como resultado, el cuestionario de la estrategia didáctica mediada por IA obtuvo valoraciones de 95 y 95, mientras que la prueba de conocimientos de Matemática Discreta alcanzó puntajes de 95 y 94. En ambos casos, los resultados se ubicaron en el nivel muy bueno, lo que permitió considerar los instrumentos como adecuados y aplicables para los fines del estudio.

Respecto de la confiabilidad, el cuestionario tipo Likert fue sometido al análisis de consistencia interna mediante el coeficiente alfa de Cronbach, obteniéndose un valor de 0.964, indicador que corresponde a una consistencia interna excelente (Hernández-Sampieri & Mendoza, 2018). En términos prácticos, este valor muestra que los ítems mantienen una relación coherente entre sí y que el instrumento funciona de manera estable al momento de recoger la información. Por ello, se considera que

el cuestionario es confiable para su uso en el estudio y para sustentar el análisis posterior de los datos.

Tabla 4

Confiabilidad de la prueba de conocimientos de Matemática Discreta

Indicador	Valor
Número de estudiantes	150
Número de Items	12
Tipo de respuesta	Dicotómica
Tiempo de aplicación	45 minutos
KR-20 (Pretest)	0.860
KR-20 (Posttest)	0.869
Interpretación	Alta confiabilidad

Nota: Elaboración propia.

Como se observa en la Tabla 4, la prueba de conocimientos alcanzó coeficientes KR-20 de 0.860 en el pretest y 0.869 en el posttest. Estos valores evidencian una adecuada consistencia interna en ambas aplicaciones, indicando que los ítems presentan una relación homogénea y permiten medir de manera confiable el aprendizaje de Matemática Discreta. En consecuencia, la prueba reúne condiciones satisfactorias para su utilización en el estudio.

Tabla 5

Indicadores de equivalencia entre las formas pretest y posttest

Indicador	Pretest	Posttest
Número de ítems	12	12
Lógica proposicional	4	4
Relaciones	4	4
Teoría de grafos	4	4
Tiempo de aplicación	45 min	45 min
Puntaje máximo	24 puntos	24 puntos
Dificultad promedio	0.437	0.572
Discriminación promedio	0.534	0.550

Nota: Elaboración propia.

Como se observa en la Tabla 5, las formas utilizadas en el pretest y posttest conservaron la misma estructura, distribución temática, tiempo de aplicación y puntaje máximo. Asimismo, los indicadores de dificultad y discriminación mostraron valores adecuados en ambas aplicaciones, lo que proporciona evidencia favorable de equivalencia entre las dos formas de evaluación. Estos resultados respaldan que las diferencias observadas entre el pretest y el posttest pueden atribuirse al efecto de la intervención y no a variaciones sustanciales en la estructura o complejidad de los instrumentos utilizados.

3.1.7. Monitoreo del cumplimiento del protocolo de ingeniería de prompts

Con el propósito de garantizar la aplicación consistente de la estrategia didáctica mediada por inteligencia artificial, durante las cuatro semanas de intervención se realizó un seguimiento permanente del uso de los prompts estructurados por parte de los estudiantes. Este monitoreo permitió verificar que las actividades desarrolladas se ajustaran a la secuencia pedagógica prevista para cada uno de los contenidos trabajados.

El seguimiento se efectuó mediante la revisión de las evidencias generadas durante las sesiones prácticas, la supervisión directa del docente y la verificación de los productos académicos elaborados por los estudiantes. Asimismo, se observó el cumplimiento de aspectos relacionados con la formulación adecuada de instrucciones, la interacción secuencial con la herramienta, la justificación de respuestas y la revisión crítica de los resultados obtenidos. Estos procedimientos contribuyeron a asegurar una implementación homogénea de la estrategia en el grupo participante y a fortalecer la consistencia metodológica de la intervención desarrollada (Hernández-Sampieri & Mendoza, 2018; Creswell & Creswell, 2023).

3.1.8. Implementación de la estrategia didáctica mediada por inteligencia artificial

La estrategia didáctica mediada por inteligencia artificial se implementó durante cuatro semanas consecutivas como parte del desarrollo de la asignatura de Matemática Discreta en estudiantes del primer ciclo de Ciencia de Datos. La intervención se desarrolló en el laboratorio de cómputo de la universidad mediante sesiones de dos horas de duración, respetando la programación académica del curso y los contenidos establecidos en el sílabo.

La estrategia estuvo orientada a fortalecer el aprendizaje de lógica proposicional, relaciones y su representación mediante matrices y grafos dirigidos, así como teoría de grafos, mediante una interacción guiada con herramientas de inteligencia artificial generativa. Para el desarrollo de las actividades se utilizaron ChatGPT, DeepSeek, Claude, Microsoft Copilot y Gemini como recursos de apoyo al aprendizaje. Su empleo estuvo regulado mediante prompts estructurados diseñados previamente para cada uno de los contenidos desarrollados durante la intervención, garantizando que la interacción respondiera a los objetivos de aprendizaje previstos en cada sesión.

Las actividades fueron desarrolladas de manera individual, permitiendo que cada estudiante interactuara directamente con las herramientas de inteligencia artificial siguiendo una secuencia metodológica previamente establecida. Esta modalidad favoreció la participación activa durante el proceso de resolución de problemas y permitió al docente realizar un seguimiento continuo del desempeño alcanzado por cada estudiante.

Con el propósito de garantizar la aplicación homogénea de la estrategia didáctica, para cada sesión se dispuso de un repositorio digital compartido (Google

Drive) que contenía el prompt estructurado correspondiente al contenido desarrollado. Los estudiantes accedían al enlace al inicio de la actividad y utilizaban el prompt como guía para interactuar con las herramientas de inteligencia artificial. Cada prompt fue elaborado considerando los tres componentes definidos en el protocolo de ingeniería de prompts de la investigación: System Role, encargado de establecer el rol que debía asumir la herramienta de inteligencia artificial; Instrucción Obligatoria, donde se especificaban las acciones que debía desarrollar durante la interacción; y Mecanismo de Control, orientado a verificar que las respuestas promovieran el razonamiento, la justificación de los procedimientos y la validación de los resultados antes de llegar a una respuesta final.

Cada sesión inició con la presentación del contenido correspondiente y del problema o situación de aprendizaje que sería desarrollado. El docente explicó los objetivos de la actividad, recordó los conceptos matemáticos necesarios para su resolución y brindó las orientaciones iniciales para el desarrollo del trabajo. Posteriormente, los estudiantes iniciaron la interacción con la herramienta de inteligencia artificial utilizando el prompt estructurado correspondiente a la sesión.

Durante esta etapa, la inteligencia artificial proporcionó orientaciones progresivas para el análisis del problema, formuló preguntas que favorecían el razonamiento matemático, solicitó la justificación de los procedimientos desarrollados y promovió la verificación de los resultados obtenidos antes de continuar con la siguiente etapa de resolución. Cuando se identificaban errores de interpretación o inconsistencias en el procedimiento, la interacción conducía al estudiante a revisar su razonamiento mediante nuevas preguntas y sugerencias, evitando proporcionar directamente la solución final.

No obstante, el acceso a los prompts no implicó un trabajo autónomo sin acompañamiento docente. Durante toda la sesión, el investigador interactuó permanentemente con los estudiantes, orientando el desarrollo de las actividades, resolviendo dudas conceptuales y verificando que el proceso de resolución siguiera la secuencia establecida en el protocolo de ingeniería de prompts. Asimismo, evitó que los estudiantes adelantaran etapas de la resolución sin haber comprendido los procedimientos previos y promovió el análisis crítico de las respuestas generadas por la inteligencia artificial. Cuando fue necesario, brindó retroalimentación inmediata, planteó preguntas orientadoras y presentó diferentes alternativas de solución con el propósito de fortalecer el razonamiento matemático y favorecer la comprensión de los conceptos desarrollados.

Al concluir cada sesión, se realizó una retroalimentación conjunta en la que se revisaron los procedimientos empleados por los estudiantes, se analizaron los errores más frecuentes y se discutieron distintas estrategias de resolución para los problemas desarrollados. Finalmente, el docente verificó que los estudiantes pudieran explicar y justificar los procedimientos realizados antes de dar por concluida la actividad, asegurando que el aprendizaje estuviera sustentado en la comprensión de los fundamentos matemáticos y no únicamente en las respuestas proporcionadas por las herramientas de inteligencia artificial.

Con el propósito de mantener condiciones homogéneas durante toda la intervención, las cuatro semanas conservaron la misma secuencia metodológica, variando únicamente los contenidos correspondientes a cada unidad temática. Esta organización permitió garantizar la consistencia en la implementación de la estrategia didáctica y asegurar que todos los participantes desarrollaran las actividades bajo condiciones equivalentes durante el periodo de estudio.

Con el propósito de sintetizar la organización de la intervención, la Tabla 6 presenta la distribución de las actividades desarrolladas durante las cuatro semanas de implementación de la estrategia didáctica mediada por inteligencia artificial. En ella se describen los contenidos abordados, los recursos empleados, la modalidad de trabajo y el propósito pedagógico de cada sesión, evidenciando la secuencia metodológica seguida durante el proceso de intervención.

Tabla 6

Semana	Contenido	Actividad de aprendizaje	Recursos de IA	Producto esperado
1	Lógica proposicional	Resolución guiada de problemas mediante prompts estructurados, análisis de proposiciones, tablas de verdad y equivalencias lógicas.	ChatGPT, DeepSeek, Claude , Microsoft Copilot y Gemini	Resolución fundamentada de ejercicios de lógica proposicional y justificación de los procedimientos empleados.
2	Relaciones y su representación mediante matrices y grafos dirigidos	Identificación de propiedades de relaciones, construcción de matrices y representación de grafos mediante interacción guiada con IA.	ChatGPT, DeepSeek, Claude , Microsoft Copilot y Gemini	Representación correcta de relaciones y análisis de sus propiedades mediante procedimientos justificados.
3	Teoría de grafos	Resolución de problemas relacionados con caminos, ciclos, conectividad y otras propiedades de grafos utilizando prompts estructurados.	ChatGPT, DeepSeek, Claude , Microsoft Copilot y Gemini	Resolución argumentada de problemas de teoría de grafos y validación de los resultados obtenidos.
4	Integración de contenidos	Desarrollo de ejercicios integradores, revisión de procedimientos, retroalimentación y consolidación de los aprendizajes alcanzados durante la intervención.	ChatGPT, DeepSeek, Claude , Microsoft Copilot y Gemini	Integración de los contenidos desarrollados y fortalecimiento del razonamiento matemático para la evaluación final.

Nota: Elaboración propia

3.2. Diseño Muestral

3.2.1. Población

Desde una perspectiva estadística, la población corresponde al conjunto total de unidades de análisis que comparten características relevantes para el estudio y sobre las cuales se pretende describir o analizar un fenómeno determinado (López, 2004). En investigaciones educativas, su delimitación precisa permite definir el universo de referencia y sustentar la pertinencia de los procedimientos de medición y análisis (Bernal, 2016).

En la presente investigación, la población estuvo conformada por 150 estudiantes matriculados en el primer ciclo de la carrera de Ciencia de Datos de una universidad limeña durante el periodo académico 2026. Todos los participantes cursaban la asignatura de Matemática Discreta y compartían características académicas similares en cuanto a nivel de formación y plan curricular.

Para formar parte del estudio se establecieron los siguientes criterios de inclusión: (a) estar matriculado en la asignatura durante el periodo de intervención, (b) asistir regularmente a las sesiones programadas y (c) participar tanto en la evaluación diagnóstica (pretest) como en la evaluación final (postest).

Asimismo, se consideraron como criterios de exclusión: (a) registrar inasistencias superiores al 20 % de las sesiones de intervención, (b) no completar alguna de las mediciones principales del estudio y (c) presentar registros incompletos que impidieran realizar el análisis comparativo entre pretest y postest.

En la Tabla 7 se presenta la población del estudio, conformada por 150 estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña (2026), considerada en su totalidad para el análisis.

Tabla 7*Población del estudio*

Descripción	Población
Estudiantes del primer ciclo de Ciencia de Datos	150
Población total del estudio	150

Nota: Elaboración propia.

3.2.2. Muestra

La muestra estuvo conformada por la totalidad de estudiantes que integraban la población accesible del estudio, por lo que se trabajó bajo criterio censal. Este procedimiento resulta pertinente cuando se dispone de acceso a todos los integrantes de la población objetivo, permitiendo analizar de manera directa las variaciones observadas entre las mediciones pretest y posttest sin recurrir a procedimientos de selección muestral (Hernández-Sampieri & Mendoza, 2018).

Asimismo, durante el periodo de intervención no se registraron abandonos ni pérdidas de participantes, por lo que el análisis estadístico se efectuó con la totalidad de los registros obtenidos. En consecuencia, la cobertura del estudio alcanzó el 100 % de la población considerada.

La Tabla 7 presenta la composición de la muestra analizada. Como se observa, la totalidad de estudiantes elegibles cumplió los criterios de inclusión establecidos para la investigación, sin registrarse exclusiones ni abandonos durante el periodo de intervención. Asimismo, todos los participantes completaron las evaluaciones de pretest y posttest, por lo que el análisis estadístico se realizó sobre la totalidad de la muestra prevista ($n = 150$), garantizando una cobertura del 100 % de la población considerada en el estudio.

Tabla 7*Muestra del estudio según criterio censal*

Descripción	(n)	Cobertura (%)
Estudiantes del primer ciclo de Ciencia de Datos elegibles para el estudio	150	100
Estudiantes que cumplieron los criterios de inclusión	150	100
Estudiantes excluidos	0	0
Abandonos durante la intervención	0	0
Estudiantes con pretest completo	150	100
Estudiantes con posttest completo	150	100
Muestra final analizada	150	100

Nota: Elaboración propia.

3.3. Procesamiento de datos

El procesamiento de datos se desarrolló de manera secuenciada, con el propósito de asegurar orden, trazabilidad y rigor en el análisis cuantitativo. En una primera etapa, se realizó la codificación de la información, asignando valores numéricos a las categorías de respuesta del cuestionario tipo Likert para facilitar su tratamiento estadístico.

Para la gestión inicial de la base de datos se utilizó el entorno de computación en la nube Google Colab mediante el lenguaje de programación Python. Con apoyo de la librería Pandas, se efectuó la carga, limpieza y depuración de los registros, verificando la integridad de la matriz antes del análisis. Una vez organizada la información, se estructuró la base de datos de manera que las filas representaran a

los participantes y las columnas correspondieran a las variables, dimensiones e ítems de los instrumentos aplicados (Hernández-Sampieri & Mendoza, 2018).

Posteriormente, se llevó a cabo el análisis descriptivo mediante medidas de tendencia central y dispersión. En el caso del cuestionario, se calcularon medias y desviaciones estándar por ítem y por dimensión, con el fin de identificar patrones generales asociados a la estrategia didáctica mediada por inteligencia artificial. En cuanto al aprendizaje, se estimaron medidas descriptivas del pretest y del posttest para describir tanto el desempeño inicial como el alcanzado después de la intervención.

Además, se emplearon las librerías Matplotlib y Seaborn para generar visualizaciones, como histogramas de frecuencia y diagramas de caja, lo que permitió reconocer tendencias generales y organizar la evidencia antes del contraste inferencial (Creswell & Creswell, 2023). Finalmente, se evaluó la calidad del cuestionario mediante consistencia interna, aplicando el coeficiente alfa de Cronbach. Este análisis aportó evidencia de confiabilidad y respaldó el uso del instrumento para describir la variable asociada a la estrategia mediada por inteligencia artificial (Hernández-Sampieri & Mendoza, 2018).

3.4. Aspectos éticos

La investigación se guio por principios éticos fundamentales reconocidos en la literatura bioética y metodológica, entre ellos la autonomía, la justicia y la beneficencia (Espinoza & Calva, 2020).

En concordancia con estos principios, se garantizó la participación voluntaria de los estudiantes mediante el consentimiento informado, brindándoles información clara sobre los objetivos del estudio, el carácter académico de la investigación y el uso de los datos recolectados. Asimismo, se resguardó la confidencialidad de la

información y se procuró que la participación en el estudio no ocasionara perjuicio alguno en el desarrollo académico de los participantes. Estas medidas permitieron preservar la integridad del proceso investigativo y asegurar el respeto por los estudiantes involucrados (Espinoza & Calva, 2020).

3.5. Tratamiento estadístico

La estadística se empleó como soporte para organizar, analizar e interpretar los datos con criterios de objetividad. En el presente estudio se recurrió a estadística descriptiva e inferencial para sustentar conclusiones basadas en evidencia cuantificable (Hernández-Sampieri & Mendoza, 2018; Creswell & Creswell, 2023).

En la fase descriptiva se calcularon medias y desviaciones estándar del pretest y posttest, y se describieron los resultados del cuestionario tipo Likert por ítems y dimensiones, presentándolos mediante tablas y figuras. Como apoyo para la visualización de los datos, se utilizaron las librerías Seaborn y Matplotlib en el entorno Google Colab, lo que permitió representar gráficamente la distribución y dispersión de los puntajes.

En la fase inferencial, los datos se procesaron mediante Python en Google Colab. La contrastación de hipótesis se realizó con la prueba t de Student para muestras relacionadas, adecuada para comparar dos mediciones efectuadas sobre el mismo grupo. Antes de aplicar esta prueba, se verificó el supuesto de normalidad mediante la prueba de Kolmogorov-Smirnov, con el propósito de sustentar la pertinencia del estadístico paramétrico. Se adoptó un nivel de significancia de $\alpha = 0.05$ y se reportó el valor p, el intervalo de confianza del 95 % para la diferencia de medias y el tamaño del efecto (d de Cohen), a fin de complementar la significancia estadística con una lectura de la magnitud práctica del cambio observado (Creswell & Creswell, 2023). En términos generales, la prueba de hipótesis permite evaluar la

evidencia empírica a favor o en contra de una afirmación mediante la comparación entre la hipótesis nula (H_0) y la hipótesis alternativa (H_1), tomando decisiones con base en α y en el valor p (Quevedo, 2011).

En este estudio, la regla de decisión fue la siguiente: si $p < 0.05$, se rechazó H_0 ; si $p \geq 0.05$, no se rechazó H_0 . Este procedimiento permitió sustentar, con evidencia estadística, la conclusión sobre el efecto de la estrategia didáctica mediada por inteligencia artificial en el aprendizaje de Matemática Discreta.

Tabla 8

Criterios para la contrastación de la hipótesis general.

Elemento	Descripción
Hipótesis nula (H_0)	$\mu_{post} = \mu_{pre}$
Interpretación de H_0	No existe diferencia significativa entre el puntaje promedio del postest y el pretest
Hipótesis alternativa (H_1)	$\mu_{post} \neq \mu_{pre}$
Interpretación de H_1	Existe diferencia significativa entre el puntaje promedio del postest y el pretest.
Nivel de significancia	$\alpha = 0.05$ (Nivel de confianza del 95%)
Prueba estadística	t de Student para muestras relacionadas
Unidad de análisis	Puntajes obtenidos por los mismos estudiantes ($n = 150$)
Software empleado	Python (Google Colab)
Regla de decisión	Si $p < 0.05$ se rechaza H_0 ; si $p \geq 0.05$ no se rechaza H_0
Magnitud del impacto	Tamaño del efecto (d de Cohen) e intervalo de confianza

Nota: Elaboración propia

En esta investigación, la contrastación de la hipótesis general se efectuó mediante un cuadro de decisión estadística que reunió la formulación de hipótesis, el nivel de significancia, la prueba aplicada y la regla de decisión correspondiente. Dado que se compararon dos mediciones del mismo grupo de estudiantes, se utilizó la prueba t de Student para muestras relacionadas. La interpretación de los resultados

se basó en el valor p y se complementó con el intervalo de confianza del 95 % para la diferencia de medias y con el tamaño del efecto, con el propósito de valorar tanto la significancia estadística como la magnitud práctica del cambio observado.

Capítulo IV – Resultados

4.1. Análisis Descriptivo

4.1.1. Validez y confiabilidad de los instrumentos

Antes de presentar los resultados del estudio, corresponde señalar que los instrumentos utilizados contaron con evidencias de validez y confiabilidad suficientes para su aplicación. En cuanto a la validez de contenido, esta fue establecida mediante juicio de expertos. En total participaron cuatro especialistas: dos encargados de evaluar el cuestionario sobre la estrategia didáctica mediada por inteligencia artificial y dos responsables de revisar la prueba de conocimientos de Matemática Discreta.

En el caso del cuestionario, los expertos otorgaron valoraciones de 95 y 95 puntos. Por su parte, la prueba de conocimientos obtuvo puntajes de 95 y 94. De acuerdo con la escala de valoración empleada, estos resultados ubican a ambos instrumentos en el nivel muy bueno, lo que respalda su claridad, coherencia, pertinencia y aplicabilidad para los fines del estudio.

Tabla 9

Validación del instrumento por juicio de expertos

Nombre de los expertos	Cuestionario de la estrategia didáctica por IA
Dr. Julio César Lanazca Vargas	95%
Mg. Joe Lope Vicente	96%
Mg. Giovanna Baldeón Penao	95%
Mg. Juan Rodríguez Barrenechea	95%
Promedio del puntaje de los expertos	95%

Nota: Elaboración propia.

La evaluación realizada por los jueces expertos permitió establecer el nivel de validez de contenido del instrumento. Una vez consignadas las valoraciones definitivas, se pudo determinar que el cuestionario presenta niveles adecuados de pertinencia, claridad y coherencia para su aplicación en el estudio. Estos resultados se contrastan con los niveles de validez establecidos por la institución:

Tabla 10

Valores de los niveles de validez según UDEA

Valores	Niveles de validez
96 –100	Excelente
91 – 95	Muy bueno
86 – 90	Bueno
80 – 85	Regular
≤ 79	Deficiente

Nota: Elaboración propia

Confiabilidad del instrumento

Para evaluar la confiabilidad del instrumento se utilizó el coeficiente alfa de Cronbach (α), un indicador ampliamente aceptado de la consistencia interna. Este coeficiente permite estimar el grado de asociación promedio entre los ítems que conforman la escala; en ese sentido, su valor aumenta a medida que se fortalecen las intercorrelaciones entre los reactivos que miden un mismo constructo.

Dado que la variable fue operacionalizada mediante una escala tipo Likert, se consideró pertinente emplear este coeficiente. La confiabilidad fue estimada mediante Python en Google Colab, obteniéndose un valor de $\alpha = 0.964$, el cual evidencia un nivel de consistencia interna excelente. En consecuencia, se consideró que el instrumento presentaba condiciones adecuadas para su aplicación en la investigación.

4.1.2. Resultados de la variable desempeño académico (Pretest y Postest)

El análisis descriptivo permitió examinar el comportamiento de los puntajes obtenidos por los estudiantes antes y después de la aplicación de la estrategia didáctica mediada por inteligencia artificial en el curso de Matemática Discreta. Para ello se analizaron los resultados del pretest y del postest, considerando medidas de tendencia central y dispersión que permiten describir el desempeño del grupo en ambos momentos de medición.

Tabla 11

Estadísticos descriptivos de los puntajes de pretest y postest

Medición	N	Media	Desviación estándar
Pretest	150	10.50	1.68
Postest	150	13.75	1.91

Nota. Elaboración propia


Como se observa en la Tabla 11, el puntaje promedio del pretest fue de 10.50, con una desviación estándar de 1.68, mientras que en el postest el promedio se incrementó a 13.75, con una desviación estándar de 1.91. Estos resultados muestran, a nivel descriptivo, una mejora en el desempeño académico de los estudiantes después de la implementación de la estrategia didáctica mediada por IA.

El incremento de 3.25 puntos entre ambas mediciones permite apreciar una mejora en el rendimiento del grupo después de la intervención. A ello se suma que la dispersión de los puntajes se mantuvo en niveles semejantes, lo que sugiere que el avance no fue aislado, sino más bien compartido por una parte importante de los estudiantes. En términos académicos, el aumento de la media refleja un mejor logro en los contenidos evaluados de Matemática Discreta. Por ello, desde el plano

descriptivo, los resultados muestran una evolución favorable del aprendizaje luego de la aplicación de la estrategia didáctica mediada por inteligencia artificial.

Figura 4

Comparación de puntajes promedio entre pretest y posttest



Nota: Comparación de puntajes promedio entre pretest y posttest, procesados en Python mediante Google Colab.


Interpretación y Análisis

Los resultados presentados en la Tabla 11 y la Figura 4 evidencian que el puntaje promedio de los estudiantes aumentó de 10.50 en el pretest a 13.75 en el posttest. Esta diferencia descriptiva muestra una mejora en el rendimiento académico después de la implementación de la estrategia didáctica mediada por inteligencia artificial. Aunque en ambas mediciones se observa una variabilidad moderada de los puntajes, el incremento del promedio sugiere que la intervención contribuyó favorablemente al aprendizaje de Matemática Discreta en los estudiantes evaluados.

De manera complementaria, este comportamiento permite advertir una tendencia general de mejora en el grupo intervenido, lo que refuerza la lectura positiva de los resultados descriptivos. Si bien esta evidencia no agota por sí sola la interpretación del efecto de la intervención, sí ofrece un primer respaldo empírico sobre su aporte en el proceso de aprendizaje. En esa línea, el aumento del promedio entre ambas mediciones resulta coherente con el propósito pedagógico de fortalecer el desempeño académico de los estudiantes mediante el uso de recursos apoyados en inteligencia artificial.

Figura 5

Distribución de las diferencias entre posttest y pretest



Nota: *Distribución de las diferencias entre posttest y pretest*, procesados en Python mediante Google Colab.

Interpretación y Análisis

Los resultados presentados en la Figura 5 muestran que la distribución de las diferencias entre el posttest y el pretest se concentra principalmente en valores

positivos. Esto indica que la mayoría de los estudiantes obtuvo puntajes más altos después de la intervención que antes de ella. En términos descriptivos, estos hallazgos respaldan la existencia de una mejora general en el aprendizaje de Matemática Discreta tras la aplicación de la estrategia didáctica mediada por IA.

4.1.2.1. Resultados descriptivos según dimensiones del aprendizaje

Con la finalidad de profundizar en el análisis del desempeño académico, se examinaron los resultados del pretest y del postest según las dimensiones del aprendizaje de Matemática Discreta: lógica proposicional, relaciones y su representación mediante matriz y grafo dirigido, y teoría de grafos. Este análisis permitió observar con mayor detalle el comportamiento del aprendizaje en cada uno de los componentes trabajados durante la intervención.

Tabla 12

Resultados descriptivos del aprendizaje según dimensiones

Dimensión	Pretest	Postes	Diferencia
Lógica proposicional	3.30	4.30	1.68
Relaciones y su representación mediante matriz y grafo	3.50	4.65	1.91
Teoría de grafos	3.70	4.80	1.10
Total	10.50	13.75	3.25

Nota: Resultados descriptivos del aprendizaje según dimensiones, obtenido del software

Python mediante Google Colab.


Como se observa en la Tabla 12, en las tres dimensiones evaluadas los puntajes promedio del postest superaron a los del pretest. En lógica proposicional, el promedio pasó de 3.30 a 4.30; en relaciones y su representación mediante matriz y grafo dirigido, de 3.50 a 4.65; y en teoría de grafos, de 3.70 a 4.80. En conjunto, estos

resultados muestran una mejora sostenida en cada uno de los componentes del aprendizaje evaluado.

La dimensión que alcanzó el promedio más alto en el posttest fue teoría de grafos, seguida de relaciones y su representación mediante matriz y grafo dirigido, mientras que lógica proposicional también mostró un avance favorable. Esto permite sostener que la mejora del aprendizaje no se produjo únicamente a nivel global, sino también en los componentes específicos que estructuraron la prueba de conocimientos.

Figura 6

Comparación de puntajes promedio por dimensiones del aprendizaje en el pretest y posttest



Nota: Comparación de puntajes promedio por dimensiones del aprendizaje en el pretest y posttest, obtenido del software Python mediante Google Colab

Interpretación y Análisis

La Figura 6 muestra que, en las tres dimensiones evaluadas, los puntajes promedio del posttest fueron superiores a los del pretest. Esta tendencia permite

apreciar que el avance del grupo no se concentró en un solo contenido, sino que se extendió a los distintos componentes del curso. En ese sentido, la intervención favoreció de manera conjunta el razonamiento lógico, la comprensión de relaciones y la interpretación de estructuras gráficas, todos ellos aspectos centrales en la formación inicial de los estudiantes de Ciencia de Datos.

a) Dimensión: Lógica proposicional

En la dimensión lógica proposicional, el puntaje promedio pasó de 3.30 en el pretest a 4.30 en el posttest, lo que representa una diferencia de 1.00 punto. Este resultado muestra una mejora en la capacidad de los estudiantes para reconocer proposiciones, interpretar conectores lógicos, elaborar tablas de verdad y analizar la validez de argumentos. En términos académicos, se aprecia un avance en el razonamiento formal después de la intervención.

b) Dimensión: Relaciones y su representación mediante matriz y grafo dirigido

En la dimensión relaciones y su representación mediante matriz y grafo dirigido, el puntaje promedio aumentó de 3.50 en el pretest a 4.65 en el posttest, con una diferencia de 1.15 puntos. Este resultado sugiere una mejora en la identificación de propiedades de las relaciones y en su representación mediante matrices y grafos dirigidos. Desde una lectura descriptiva, ello indica que los estudiantes alcanzaron una comprensión más ordenada de este contenido después de la estrategia aplicada.

c) Dimensión: Teoría de grafos

En la dimensión teoría de grafos, el promedio se elevó de 3.70 en el pretest a 4.80 en el posttest, reflejando una diferencia de 1.10 puntos. Este incremento muestra un mejor desempeño en el reconocimiento de vértices, aristas, grados y propiedades básicas de los grafos, así como en la resolución de ejercicios vinculados con este

contenido. En términos descriptivos, esta dimensión presenta el promedio final más alto, lo que sugiere un avance favorable en el razonamiento gráfico y relacional de los estudiantes.

En conjunto, los resultados descriptivos por dimensiones permiten sostener que la mejora del aprendizaje no solo se observó a nivel global, sino también en cada uno de los componentes específicos evaluados. La media más alta en el posttest se registró en teoría de grafos, seguida de relaciones y su representación mediante matriz y grafo dirigido y lógica proposicional. Esto respalda la idea de que la estrategia didáctica mediada por inteligencia artificial favoreció el aprendizaje de Matemática Discreta de manera integral.

4.2. Análisis Inferencial

Contrastación de las hipótesis

En el presente estudio, para la verificación de las hipótesis, se aplicó inicialmente una prueba de normalidad a los puntajes obtenidos en el pretest y posttest, así como a las diferencias entre ambas mediciones. Para ello, se plantearon las siguientes hipótesis:

- Hipótesis nula (H_0): Los datos presentan una distribución normal.
- Hipótesis alternativa (H_1): Los datos no presentan una distribución normal.

Se estableció un nivel de significancia de $\alpha = 0.05$, equivalente a un 95 % de confianza.

Regla de decisión

- Si $p \leq 0.05$ se rechaza H_0 y se concluye que los datos no presentan una distribución normal; en ese caso, corresponde aplicar pruebas no paramétricas.
- Si $p < 0.055$, no se rechaza H_0 y se concluye que los datos presentan una distribución aproximadamente normal; en ese caso, corresponde aplicar pruebas paramétricas.

Debido a que la muestra estuvo conformada por 150 estudiantes, se empleó la prueba de Kolmogorov-Smirnov con la finalidad de verificar el supuesto de normalidad requerido para el análisis paramétrico. Su aplicación permitió determinar si la distribución de los puntajes, así como de las diferencias entre el pretest y el posttest, era compatible con una distribución normal. A partir de ello, se sustentó el uso de la prueba t de Student para muestras relacionadas como procedimiento inferencial del estudio.

Tabla 13

Prueba de normalidad – Kolmogorov-Smirnov de los puntajes globales de pretest y posttest

Variable	Estadístico	Grados de libertad	Significancia
Pretest global	0.037	150	0.981
Posttest global	0.049	150	0.851

Nota: Resultados de la prueba de normalidad, obtenido del software *Python* mediante *Google Colab*.

En la Tabla 13 se observa que los valores de significancia del pretest global y del posttest global fueron 0.981 y 0.851, respectivamente, ambos superiores al nivel de 0.05. Estos resultados indican que no existen evidencias suficientes para rechazar la hipótesis de normalidad en ninguna de las dos mediciones. En ese sentido, se asume que los puntajes presentan una distribución aproximadamente normal, condición que respalda la aplicación de una prueba paramétrica.


Este resultado es consistente con el diseño preexperimental de la investigación, en el que se comparan dos mediciones realizadas al mismo grupo de estudiantes antes y después de la intervención. Por ello, la prueba t de Student para muestras relacionadas resultó pertinente para evaluar si las diferencias observadas entre ambos momentos eran estadísticamente significativas. Así, la verificación previa

del supuesto de normalidad permitió dar mayor solidez al análisis inferencial realizado.

Con el propósito de complementar la verificación del supuesto de normalidad, se realizó una inspección gráfica de las diferencias entre los puntajes del postest y pretest. En la Figura 7 se presenta el histograma de dichas diferencias, lo que permite observar la forma general de su distribución.

Figura 7

Histograma de las diferencias entre los puntajes del postest y pretest



Nota: Elaboración propia a partir de la base de datos del estudio, procesada en Python mediante Google Colab.


Como se aprecia en la Figura 7, la distribución de las diferencias presenta un comportamiento aproximadamente normal, resultado que es consistente con los valores de significancia obtenidos en la prueba de Kolmogorov-Smirnov. En consecuencia, se ratifica la pertinencia del uso de una prueba paramétrica para la contrastación de la hipótesis general.

Asimismo, para reforzar la evaluación del supuesto de normalidad, se elaboró el gráfico Q-Q de las diferencias entre los puntajes del postest y pretest. Este recurso

gráfico permite comparar la distribución observada de los datos con la distribución normal teórica, facilitando una verificación visual complementaria del cumplimiento del supuesto de normalidad.

Figura 8

Gráfico Q-Q de las diferencias entre los puntajes del posttest y pretest



Nota: Gráfico Q-Q a partir de la base de datos procesada en Python mediante Google Colab.

Tal como se observa en la Figura 8, la mayor parte de los puntos se ubica próxima a la línea diagonal de referencia, lo que indica que la distribución de las diferencias entre posttest y pretest se aproxima a una distribución normal. Este resultado respalda visualmente lo evidenciado en la prueba de Kolmogorov-Smirnov y confirma la pertinencia de aplicar la prueba *t* de Student para muestras relacionadas.

Los resultados de la prueba de normalidad de Kolmogorov-Smirnov, presentados en la Tabla 13, evidencian que tanto en los puntajes globales del pretest y posttest como en las diferencias obtenidas entre ambas mediciones, los valores de significancia fueron superiores a 0.05. En consecuencia, no se rechazó la hipótesis

nula, lo que indica que los datos presentan una distribución aproximadamente normal. A partir de ello, se determinó el uso de una prueba paramétrica, específicamente la prueba t de Student para muestras relacionadas, debido a que el estudio corresponde a un diseño preexperimental con medición antes y después de la intervención en un mismo grupo de estudiantes.

Hipótesis general

Planteamiento de la hipótesis

H_0 : La estrategia didáctica mediada por inteligencia artificial no mejora significativamente el aprendizaje de Matemática Discreta en los estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, 2026.

H_1 : La estrategia didáctica mediada por inteligencia artificial mejora significativamente el aprendizaje de Matemática Discreta en los estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, 2026.

Nivel de significación

Se estableció un nivel de confianza del 95 %, lo que corresponde a un nivel de significación de $\alpha = 0.05$.

Prueba estadística aplicada

Para la contrastación de la hipótesis general se empleó la prueba t de Student para muestras relacionadas, dado que se compararon los puntajes del pretest y posttest obtenidos por los mismos 150 estudiantes antes y después de la aplicación de la estrategia didáctica mediada por IA.

Regla de decisión

- Si el valor de p es menor o igual a 0.05, se rechaza la hipótesis nula y se acepta la hipótesis alternativa.
- Si el valor de p es mayor que 0.05, no se rechaza la hipótesis nula. Resultado de la contrastación.

Tabla 14

Contrastación de la hipótesis general

Comparación	Diferencia media	t	Grado	p valor	IC 95%	Tamaño del efecto
Postes - Pretest	3.25	41.64	1.49	< 0.001	[3.10,3.40]	3.40

Nota: Resultados de la contrastación de la hipótesis general , obtenido del software *Python* mediante *Google Colab*.

Resultado de la contrastación

La prueba t de Student para muestras relacionadas evidenció diferencias estadísticamente significativas entre los puntajes del pretest y del posttest. El promedio pasó de 10.50 en el pretest a 13.75 en el posttest, lo que representa una diferencia media de 3.25 puntos a favor del posttest. Asimismo, el análisis inferencial confirmó que dicha diferencia fue significativa ($t(149) = 41.64; p < 0.001$), por lo que se rechazó la hipótesis nula y se aceptó la hipótesis alternativa. En consecuencia, se concluye que la estrategia didáctica mediada por inteligencia artificial mejoró significativamente el aprendizaje de Matemática Discreta en los estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, 2026. Además, el tamaño del efecto obtenido ($d = 3.40$) indica que la mejora también fue relevante en términos prácticos y pedagógicos.

Capítulo V – Discusión

Los resultados obtenidos en esta investigación permiten sostener que la estrategia didáctica mediada por inteligencia artificial se asoció con una mejora significativa en el aprendizaje de Matemática Discreta en estudiantes del primer ciclo de Ciencia de Datos. El puntaje promedio pasó de 10.50 en el pretest a 13.75 en el posttest, con una diferencia media de 3.25 puntos. Esta variación fue confirmada por la prueba t de Student para muestras relacionadas, que evidenció diferencias estadísticamente significativas ($t(149) = 41.64; p < 0.001$) y un tamaño del efecto muy grande ($d = 3.40$). En términos académicos, estos resultados indican que la mejora observada no fue menor ni circunstancial, sino lo suficientemente amplia como para ser reconocida como un cambio relevante en el desempeño del grupo.

Este hallazgo guarda relación con la literatura reciente sobre inteligencia artificial en educación superior, la cual coincide en que el aporte de estas tecnologías no depende solo de la herramienta, sino de la forma en que se integra al proceso de enseñanza y aprendizaje. En esa línea, Holmes et al. (2019), Chen et al. (2020), Crompton y Burke (2023) y UNESCO (2021) destacan que el valor educativo de la inteligencia artificial aparece cuando se articula con propósitos pedagógicos claros, con retroalimentación y con mediación docente. Desde esa perspectiva, los resultados de esta tesis no se entienden como efecto del uso tecnológico aislado, sino como consecuencia de una estrategia didáctica estructurada, basada en prompts, orientación progresiva y acompañamiento durante la resolución de actividades.

La pertinencia de este resultado se vuelve aún más clara cuando se examina desde el campo específico de la educación matemática. Nanda y Pradhan (2025) y Chen, Chen y Lin (2023) señalan que la inteligencia artificial viene ocupando un lugar

cada vez más visible en la enseñanza de la matemática, especialmente en procesos que requieren personalización, práctica guiada y apoyo a la comprensión conceptual. En un curso como Matemática Discreta, donde el aprendizaje exige razonamiento formal, precisión simbólica y capacidad de establecer relaciones, estos apoyos pueden marcar una diferencia importante. En ese sentido, el incremento observado en el rendimiento del grupo resulta coherente con una línea de investigación que reconoce a la inteligencia artificial como un recurso pedagógico potencialmente valioso cuando se emplea de manera guiada y con fines formativos.

Los resultados por dimensiones refuerzan esa interpretación. En lógica proposicional, el puntaje promedio pasó de 3.30 a 4.30; en relaciones y su representación mediante matriz y grafo dirigido, de 3.50 a 4.65; y en teoría de grafos, de 3.70 a 4.80. Aunque el incremento por dimensión es menor que la variación del puntaje global, eso es metodológicamente esperable, ya que la mejora total se distribuye entre los tres componentes de la prueba. Lo importante aquí es que el avance no se concentró en una sola parte del curso, sino que se reflejó en los tres ejes que estructuraron la evaluación. Por ello, la mejora puede interpretarse como un fortalecimiento del aprendizaje de Matemática Discreta en sentido integral y no solo como un aumento localizado en un contenido específico.

En la dimensión lógica proposicional, el avance puede interpretarse como una mejora en tareas vinculadas con el reconocimiento de proposiciones, el análisis de conectores lógicos, la construcción de tablas de verdad y la evaluación de argumentos. Este resultado es consistente con lo señalado por Li y Zhong (2026), quienes sostienen que la Matemática Discreta desempeña un papel fundamental en el desarrollo del razonamiento formal y del pensamiento sistemático, constituyendo una base esencial para la formación en ciencias de la computación. Asimismo,

destacan que la organización estructurada de los contenidos favorece la comprensión de relaciones lógicas y el fortalecimiento de las capacidades de razonamiento requeridas en contextos académicos de alta exigencia.

En ese contexto, la estrategia mediada por inteligencia artificial pudo haber cumplido una función de andamiaje, permitiendo trabajar con ejemplos, reformulaciones y secuencias guiadas que facilitaron una comprensión más estable del contenido.

En la dimensión relaciones y su representación mediante matriz y grafo dirigido, la mejora observada también resulta significativa. Aquí no solo se requiere recordar definiciones, sino traducir conceptos entre distintos registros de representación. Esto coincide con lo planteado por Sandefur et al. (2022), quienes destacan la importancia de generar y articular distintas representaciones en Matemática Discreta. En el caso de esta investigación, el incremento del puntaje sugiere que la estrategia aplicada ayudó a que los estudiantes comprendieran con mayor orden la estructura de las relaciones y su representación, superando parcialmente una dificultad común en los primeros cursos de formación matemática y computacional.

La media más alta del postest se registró en teoría de grafos, lo que también merece atención. Este resultado puede relacionarse con el carácter más visual y estructural de este contenido, aspecto que suele beneficiarse de apoyos que permitan comparar ejemplos, explorar propiedades y verificar relaciones entre elementos del grafo. En ese sentido, el estudio de Marques y Sant'Ana (2024), centrado en el uso de inteligencia artificial en la enseñanza de grafos, ofrece un referente próximo para interpretar este hallazgo. No se trata de asumir que la herramienta explica por sí sola el avance, sino de reconocer que, bajo mediación docente, pudo brindar un soporte

útil para favorecer la comprensión de vértices, aristas, grados y configuraciones básicas del contenido.

La discusión también puede enriquecerse a la luz de trabajos recientes centrados directamente en Matemática Discreta y en contextos cercanos a la formación de estudiantes vinculados con computación y datos. Trouche (2025) subraya el papel central de la Matemática Discreta en la reconfiguración curricular provocada por la inteligencia artificial generativa. En una línea próxima, Lepage et al. (2026) destacan la relación entre la alfabetización en inteligencia artificial y la formación en Matemática Discreta como base para el desarrollo de competencias propias de las ciencias de la computación. De manera complementaria, Martínez, García, et al. (2024) y Martínez Guzmán et al. (2024) analizan, desde contextos universitarios, las oportunidades y desafíos asociados al uso de herramientas de inteligencia artificial en el aprendizaje de Matemática Discreta. Sus hallazgos muestran que estas tecnologías pueden favorecer la motivación, la comprensión de conceptos complejos y el rendimiento académico, siempre que su utilización esté acompañada por la supervisión y retroalimentación docente. En este marco, los resultados de la presente investigación se insertan claramente en esta discusión, pues no solo evidencian una mejora en el aprendizaje, sino que también sugieren que una integración pedagógica planificada de la inteligencia artificial puede constituir un recurso valioso para fortalecer la formación inicial de estudiantes de Ciencia de Datos.

Otro punto que da consistencia a la interpretación de los hallazgos es la calidad técnica de los instrumentos utilizados. El cuestionario alcanzó un coeficiente alfa de Cronbach de 0.964, valor que evidencia una consistencia interna excelente. A ello se suma que la validez de contenido fue respaldada mediante juicio de expertos, con valoraciones ubicadas en el nivel muy bueno. Esto no explica por sí mismo la mejora

del aprendizaje, pero sí fortalece la confianza en la calidad del soporte metodológico de la investigación, ya que los resultados se apoyan en instrumentos pertinentes, coherentes y técnicamente aceptables para los fines del estudio.

En términos didácticos, los hallazgos también pueden leerse desde marcos más amplios sobre diseño instruccional e integración pedagógica de la tecnología. Gagné (1965), Merrill (2002) y Reigeluth (1983) coinciden en que el aprendizaje mejora cuando la enseñanza organiza condiciones claras para orientar la práctica, activar conocimientos previos y conducir progresivamente al estudiante hacia tareas más complejas. A ello se suma el modelo TPACK de Mishra y Koehler (2006), que resalta la necesidad de articular contenido, pedagogía y tecnología. Tus resultados dialogan bien con estos enfoques, porque la intervención no se limitó al uso de una herramienta, sino que incorporó una secuencia organizada, objetivos definidos y acompañamiento permanente. Del mismo modo, la teoría de la carga cognitiva propuesta por Sweller (2020) ayuda a entender por qué una estrategia con apoyo guiado puede resultar especialmente útil en un curso donde los estudiantes enfrentan abstracciones nuevas y múltiples niveles de representación.

Ahora bien, la discusión de estos resultados también exige reconocer los límites del estudio. Al tratarse de un diseño preexperimental de un solo grupo con medición pretest-posttest, no corresponde afirmar una causalidad absoluta en el sentido más fuerte del término. En este punto, lo planteado por Campbell y Stanley (2015) y Hernández-Sampieri y Mendoza (2018) sigue siendo fundamental: este tipo de diseño permite estimar cambios asociados a la intervención, pero no controlar con el mismo rigor todas las amenazas a la validez interna. Por ello, la interpretación más adecuada no es decir que la inteligencia artificial, por sí sola, causó la mejora, sino

que la estrategia didáctica mediada por inteligencia artificial se asoció favorablemente con un mejor rendimiento del grupo evaluado.

Aun con esa precisión, el aporte del estudio sigue siendo importante. En el contexto actual de la educación superior, la discusión ya no gira únicamente en torno a si conviene o no usar inteligencia artificial, sino a cómo integrarla de manera responsable y pedagógicamente significativa. En esa línea, trabajos como los de Contreras y Olaya (2025), SUNEDU (2025) y European Commission (2020) muestran que la educación superior atraviesa una etapa en la que la alfabetización en inteligencia artificial, la mediación docente y la adaptación curricular se vuelven temas centrales. Tu tesis aporta a esa discusión desde un terreno concreto: evidencia que, en un curso base para la formación en Ciencia de Datos, una estrategia bien diseñada puede traducirse en mejoras observables en el aprendizaje.

En síntesis, la discusión de los hallazgos permite concluir que la estrategia didáctica mediada por inteligencia artificial se asoció de manera favorable con el aprendizaje de Matemática Discreta en los estudiantes del primer ciclo de Ciencia de Datos. La mejora del puntaje global, la significancia estadística de la diferencia, la magnitud del efecto y el avance observado en las tres dimensiones del aprendizaje convergen en una misma dirección: la intervención generó condiciones propicias para un mejor desempeño académico. Por ello, dentro del alcance del diseño empleado, los resultados respaldan la pertinencia de este tipo de estrategias en la formación inicial de estudiantes vinculados con computación, datos e IA.

Capítulo VI – Conclusiones

Primera.

Con base en el objetivo general de determinar el efecto de una estrategia didáctica mediada por inteligencia artificial en el aprendizaje de Matemática Discreta en estudiantes del primer ciclo de Ciencia de Datos de una universidad limeña, 2026, se concluye que dicha estrategia se asoció con una mejora significativa en el rendimiento académico del grupo evaluado. Esta conclusión se sustenta en la comparación entre el pretest y el posttest, donde el puntaje promedio pasó de 10.50 a 13.75, con una diferencia media de 3.25 puntos. Asimismo, la prueba t de Student para muestras relacionadas mostró un resultado estadísticamente significativo ($t(149) = 41.64; p < 0.001$), lo que permitió rechazar la hipótesis nula y aceptar la hipótesis alternativa. A ello se suma un tamaño del efecto muy grande ($d = 3.40$), lo que indica que la mejora observada no solo fue significativa en términos estadísticos, sino también importante desde el punto de vista pedagógico.

Segunda.

En relación con el objetivo específico referido al aprendizaje de lógica proposicional, se concluye que la estrategia aplicada favoreció el desarrollo del razonamiento formal en los estudiantes. El puntaje promedio de esta dimensión pasó de 3.30 en el pretest a 4.30 en el posttest, lo que muestra un avance en la identificación de proposiciones, el análisis de conectores lógicos, la construcción de tablas de verdad y la evaluación de argumentos. En consecuencia, se infiere que la intervención contribuyó a fortalecer una base central de la Matemática Discreta.

Tercera.

Respecto al objetivo específico vinculado con relaciones y su representación mediante matriz y grafo dirigido, se concluye que la intervención favoreció una

comprensión más estructurada de este contenido. El puntaje promedio pasó de 3.50 en el pretest a 4.65 en el posttest, lo que evidencia una mejora en la identificación de propiedades de las relaciones y en sus formas de representación. Este resultado sugiere que la estrategia didáctica mediada por inteligencia artificial ayudó a que los estudiantes organizaran mejor este tipo de conocimientos y los trabajaran con mayor claridad.

Cuarta.

En cuanto al objetivo específico referido a teoría de grafos, se concluye que los estudiantes alcanzaron una mejora favorable en esta dimensión. El puntaje promedio pasó de 3.70 en el pretest a 4.80 en el posttest, siendo esta la media final más alta entre las tres dimensiones evaluadas. Este resultado permite afirmar que la estrategia aplicada también favoreció el reconocimiento de vértices, aristas, grados y propiedades básicas de los grafos, así como la resolución de ejercicios asociados a este contenido.

Quinto.

Se concluye, además, que los instrumentos empleados reunieron condiciones técnicas adecuadas para el desarrollo de la investigación. La validez de contenido fue respaldada mediante juicio de expertos, con valoraciones ubicadas en el nivel muy bueno, mientras que el cuestionario de percepción alcanzó un coeficiente alfa de Cronbach de 0.964, valor que evidencia una consistencia interna excelente. En ese sentido, los resultados obtenidos se apoyan en instrumentos pertinentes, coherentes y confiables para los fines del estudio.

Sexto.

Finalmente, se concluye que la estrategia didáctica mediada por inteligencia artificial no debe entenderse como un recurso aislado ni como un sustituto de la acción

docente, sino como una mediación pedagógica que, cuando se integra con una secuencia de trabajo clara, prompts orientadores y acompañamiento permanente, puede favorecer el aprendizaje de contenidos formales en cursos iniciales de la formación universitaria. En este caso, su aplicación mostró resultados favorables en un curso clave para la formación de estudiantes de Ciencia de Datos, como es Matemática Discreta.

Capítulo VII – Recomendaciones

Primera.

A las autoridades académicas de la universidad, se recomienda promover espacios de formación orientados al uso pedagógico de herramientas de inteligencia artificial en educación superior. Contar con lineamientos claros y con programas de capacitación permitiría integrar estas tecnologías de manera responsable, pertinente y alineada con los objetivos de aprendizaje de cada asignatura.

Segunda.

A los docentes de cursos vinculados con Matemática Discreta, lógica, programación y fundamentos de Ciencia de Datos, se les recomienda incorporar estrategias didácticas mediadas por inteligencia artificial de manera planificada y guiada. La experiencia del presente estudio muestra que estas herramientas pueden contribuir al aprendizaje cuando se emplean con una secuencia clara, propósitos definidos y acompañamiento permanente del docente.

Tercero.

Se recomienda que el uso de inteligencia artificial en el aula no se reduzca a la obtención rápida de respuestas, sino que esté acompañado por actividades que promuevan análisis, justificación, contraste de procedimientos y reflexión sobre los errores. De este modo, la herramienta puede cumplir una función formativa y no solo operativa.

Cuarto.

A los estudiantes, se les recomienda utilizar las herramientas de inteligencia artificial con criterio académico y responsabilidad, aprovechándolas como apoyo para comprender conceptos, verificar procedimientos y ampliar ejemplos, pero sin

reemplazar el esfuerzo personal de razonamiento que exigen cursos como Matemática Discreta.

Quinto.

Para futuras investigaciones, se recomienda replicar este estudio en otros contextos universitarios y en otras asignaturas de base matemática o computacional, con el fin de contrastar los hallazgos obtenidos y ampliar la evidencia disponible sobre el uso educativo de la inteligencia artificial en la educación superior.

Sexto.

Asimismo, se recomienda que futuras investigaciones consideren diseños metodológicos de mayor control, por ejemplo con grupo control o con diseños cuasiexperimentales, para fortalecer la interpretación de los resultados y ampliar el nivel de evidencia sobre el efecto de este tipo de estrategias en el aprendizaje.

Referencias

- Almatrafi, O., Johri, A., & Rangwala, H. (2024). Defining AI literacy for all: Practices and values in AI education. En Proceedings of CHI 2024 .ACM
<https://doi.org/10.1145/3613904>
- Biggs, J., & Tang, C. (2011). *Teaching for quality learning at university* (4th ed.). Open University Press.
- Campbell, D. T., & Stanley, J. C. (2015). *Diseños experimentales y cuasiexperimentales en la investigación social*. Amorrortu Editores.
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- Chen, X., Xie, H., Zou, D., & Hwang, G. J. (2020). Application and theory gaps during the rise of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 1, 100002. <https://doi.org/10.1016/j.caeai.2020.100002>
- Contreras, F., & Olaya, J. C. (2025). La inteligencia artificial en la educación superior peruana: Tendencias y desafíos. *Tribunal. Revista en Ciencias de la Educación y Ciencias Jurídicas*, 5(13), 39–61. <http://doi.org/10.59659/revistatribunal.v5i13.254>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: A systematic review of empirical research from 2016 to 2022. *Computers and Education: Artificial Intelligence*, 4, 100118. <https://doi.org/10.1016/j.caeai.2023.100118>
- European Commission. (2020). Digital Education Action Plan 2021–2027: Resetting education and training for the digital age. Publications Office of the European Union.
<https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=COM:2020:624:FIN>
- Gagné, R. M. (1965). *The conditions of learning*. Holt, Rinehart and Winston.

- Gallier, J. (2020). *Discrete mathematics for computer science* (2nd ed.). Springer International Publishing. <https://doi.org/10.1007/978-3-030-46103-4>
- Guan, C., Mou, J., & Jiang, Z. (2020). Artificial intelligence innovation in education: A twenty-year data-driven historical analysis. *International Journal of Innovation Studies*, 4(4), 134–147. <https://doi.org/10.1016/j.ijis.2020.09.001>
- Grover, S., & Pea, R. (2013). Computational thinking in K–12: A review of the state of the field. *Educational Researcher*, 42(1), 38–43. <https://doi.org/10.3102/0013189X12463051>
- Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77(1), 81–112. <https://doi.org/10.3102/003465430298487>
- Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill.
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.
- Kuhail, M. A., Alturki, N., Alramlawi, S., & Al Klih, K. (2023). Interacting with educational chatbots: A systematic review. *Education and Information Technologies*, 28(1), 973–1018. <https://doi.org/10.1007/s10639-022-11177-3>
- Lepage, A., Roy, N., & Romero, M. (2026a). Developing AI literacy through discrete mathematics: A foundational model for computer science students. *International Journal of STEM Education*, 13(1), 45–62.
- Lepage, A., Roy, N., & Romero, M. (2026b). Un modèle didactique d'enseignement-apprentissage de l'intelligence artificielle issu des pratiques de médiation scientifique de la Maison de l'intelligence artificielle en France. *Sticef*, 33(1). <https://doi.org/10.23709/STICEF.33.1.2>
- Li, G., & Zhong, Y. (2026). Research on the systematization of discrete mathematics knowledge guided by big ideas. *US-China Education Review A*, 16(5), 303–310. <https://doi.org/10.17265/2161-623X/2026.05.005>

- Luckin, R. (2018). *Machine learning and human intelligence: The future of education in the 21st century*. UCL IOE Press / Springer.
- Marques, T. M., & Sant'Ana, C. C. (2024). A inteligência artificial como recurso para o ensino de Matemática: comparativo entre ChatGPT e Gemini. Anais do IX Seminário Internacional de Pesquisa em Educação Matemática (SIPEM), Natal, Rio Grande do Norte, Brasil.
- <https://www.sbembrasil.org.br/eventos/index.php/sipem/article/view/387/377>
- Martínez, A., García, M., & López, J. (2024a). Efecto de los modelos de lenguaje a gran escala en el rendimiento de Matemática Discreta en la universidad. *Revista Iberoamericana de Tecnología en Educación y Educación en Tecnología*, (36), e14.
- Martínez, S., Jiménez, G., & Sevilla, J. (2024). Oportunidades y retos de la IA en el aprendizaje de los estudiantes de la materia de Matemáticas Discretas de la carrera de ISC del TECNM Minatitlán. *Ciencia Latina Revista Científica Multidisciplinar*, 8(6), 9743–9764. https://doi.org/10.37811/cl_rcm.v8i6.14856
- Merrill, M. D. (2002). First principles of instruction. *Educational Technology Research and Development*, 50(3), 43–59. <https://doi.org/10.1007/BF02505024>
- Mishra, P., & Koehler, M. J. (2006). Technological pedagogical content knowledge: A framework for teacher knowledge. *Teachers College Record*, 108(6), 1017–1054. <https://doi.org/10.1111/j.1467-9620.2006.00684.x>
- Muzsnay, A., Szabó, C., Zámbo, C., Szabó, G., & Szeibert, J. (2025). Retrieval practice—A tool to narrow the achievement gap in learning higher mathematics. *International Journal of Science and Mathematics Education*, 23(8), 3875–3901. <https://doi.org/10.1007/s10763-025-10607-1>
- Nanda, S. B., & Pradhan, D. K. (2025). Artificial intelligence in mathematics education: A systematic review of global trends and emerging themes. *Journal of Mathematics*

Science and Technology Education, 2(2), 153–175.

<https://doi.org/10.12973/jmste.2.2.153>

Quarder, J., Schukajlow, S., Krawitz, J., Wiehe, K., & Rakoczy, K. (2025). Experiences of autonomy and competence and their reciprocal relationship: The roles of prior performance and open modelling problems in mathematics teaching. *International Journal of Science and Mathematics Education*, 23, 4127–4151.

<https://doi.org/10.1007/s10763-025-10618-y>

Reigeluth, C. M. (1983). *Instructional-design theories and models: An overview of their current status*. Lawrence Erlbaum Associates.

Sandefur, J., Lockwood, E., Hart, E., & Greefrath, G. (2022). Teaching and learning discrete mathematics. *ZDM–Mathematics Education*, 54(7), 1451–1463.

<https://doi.org/10.1007/s11858-022-01399-7>

SUNEDU. (2025). *Informe bienal sobre la realidad universitaria en el Perú: Calidad y resultados formativos*. Superintendencia Nacional de Educación Superior Universitaria.

Sweller, J. (2020). Cognitive load theory and educational technology. *Educational Technology Research and Development*, 68(1), 1–16. <https://doi.org/10.1007/s11423-019-09701-3>

Trouche, L. (2025). Intelligence artificielle et enseignement des mathématiques: continuités, ruptures et recompositions épistémologiques <https://doi.org/10.23925/2358-4122.71549>

UNESCO. (2021). *AI and education: Guidance for policy-makers*. United Nations Educational, Scientific and Cultural Organization

Wing, J. M. (2006). Computational thinking. *Communications of the ACM*, 49(3), 33–35. <https://doi.org/10.1145/1118178.1118215>