

Impacto de la Modelización Matemática asistida por IA en el desarrollo del pensamiento Variacional: Un estudio longitudinal en la Educación Superior para el Cálculo Diferencial e Integral

Impact of AI-Assisted Mathematical Modeling on the Development of Variational Thinking: A Longitudinal Study in Higher Education for Differential and Integral Calculus

Johnny Mauricio Lima-Narvaez¹, Aracely Dayanara Toapanta Ortiz², Carlos Eduardo Pule Andrade³, Michael Estuardo Ponce Rosero⁴, Esteban David Lima Narváez⁵ y Tamara Soledad Pucha Vargas⁶

¹Universidad Técnica del Norte, jmlima@utn.edu.ec, <https://orcid.org/0000-0001-7248-2211>, Ecuador

²Unidad Educativa Municipal Quitumbe, aracely.toapanta@quito.gob.ec, <https://orcid.org/0009-0002-1314-2035>, Ecuador

³Academia Pule, cepule18@gmail.com, <https://orcid.org/0009-0008-8157-2639>, Ecuador

⁴Unidad Educativa Municipal Sebastián de Benalcázar, michael.ponce@quito.gob.ec, <https://orcid.org/0009-0000-9607-9881>, Ecuador

⁵Ministerio de Educación, Deporte y Cultura, esteban.lima@docentes.educacion.edu.ec, <https://orcid.org/0009-0009-4391-886X>, Ecuador

⁶Universidad Central del Ecuador, tspucha@uce.edu.ec, <https://orcid.org/0009-0000-3392-2800>, Ecuador

Información del Artículo

Trazabilidad:

Recibido 25-01-2026

Revisado 26-01-2026

Aceptado 28-02-2026

Palabras Clave:

Inteligencia Artificial
Pensamiento Variacional
Modelización Matemática

Keywords:

Artificial Intelligence
Variational Thinking
Mathematical Modeling

RESUMEN

Los retos cognitivos que representa aprender cálculo en ingeniería son abordados por la tecnología contemporánea. Este estudio investiga la manera en que el pensamiento variacional puede ser estimulado utilizando modelización matemática respaldada por inteligencia artificial. En una investigación longitudinal, el propósito principal fue determinar la relación entre estas variables en alumnos de la facultad FICA de la Universidad Técnica del Norte. La metodología utilizada fue de carácter cuantitativo y correlacional, con una muestra compuesta por 75 estudiantes. Se empleó el instrumento IMIP-C, que cuenta con una validación mediante un Alfa de Cronbach de 0,934. Las cifras descriptivas mostraron un alto nivel de percepción de covariación (90,7%), mientras que el modelado con IA se posicionó sobre todo en un nivel medio (54,7%). La prueba de Pearson reveló una correlación positiva moderada-fuerte ($p < 0,01$; $r = 0,664$) entre el dominio técnico-instrumental de la IA y las mejores competencias para razonar simbólicamente y analizar cambios. Se concluye que la inteligencia artificial es un compañero cognitivo que reduce la carga computacional, posibilitando que el alumno se concentre en entender conceptualmente la integral y la derivada; por lo tanto, es indispensable su integración curricular de manera reflexiva.

ABSTRACT

The cognitive challenges of learning calculus in engineering are addressed by contemporary technology. This study investigates how variational thinking can be stimulated using mathematical modeling supported by artificial intelligence. In a longitudinal study, the main purpose was to determine the relationship between these variables in students of the Faculty of Engineering, Science and Technology (FICA) at the Technical University of the North. The methodology used was quantitative and correlational, with a sample of 75 students. The IMIP-C instrument, validated with a Cronbach's alpha of 0.934, was used. Descriptive statistics showed a high level of perceived covariation (90.7%), while AI modeling was primarily at a medium level (54.7%). Pearson's correlation coefficient revealed a moderate-to-strong positive correlation ($p < 0.01$; $r = 0.664$) between technical-instrumental mastery of AI and improved skills in symbolic reasoning and change analysis. It is concluded that artificial intelligence is a cognitive aid that reduces the computational load, allowing students to focus on conceptually understanding

integrals and derivatives; therefore, its thoughtful integration into the curriculum is essential.

INTRODUCCIÓN

El aprendizaje del cálculo integral y diferencial en las ingenierías supone un importante cambio cognitivo, ya que requiere una transición de un pensamiento aritmético a uno variacional dinámico. La complejidad de la educación superior actual se ha incrementado debido a la necesidad de incluir herramientas de Inteligencia Artificial (IA) como intermediarios en el proceso educativo (Baker, 2021). La dificultad es que los alumnos pueden manipular algoritmos sin cuestionar, pero no comprenden cómo las magnitudes cambian y cómo se conectan (Carlson & Thompson, 2023). Esta investigación propone que la modelización matemática basada en inteligencia artificial puede ser un "socio cognitivo" que permite al alumno centrarse en la interpretación, liberándolo de la ejecución. Para lograrlo, es necesario un estudio longitudinal que monitoree cómo evolucionan los esquemas mentales de los alumnos frente a situaciones de acumulación y cambio (Molina-Toro & Sánchez-Matamoros, 2025). Para replantear el currículo de ingeniería en términos de construir significados y no simplemente repetir procedimientos (Thompson, 2020), es fundamental analizar estas dinámicas.

La capacidad que los individuos adquieren para identificar, observar y representar la variación en distintas circunstancias con el fin de modelar el cambio se conoce como pensamiento variacional (Zahner & Corter, 2020). Esta VD supone la identificación y detección de covariación, donde el alumno tiene que encontrar las magnitudes que varían y las que permanecen estables en un fenómeno. La Ley de la Doble Formación, expuesta por Vygotsky, establece que estos procesos mentales superiores surgen inicialmente a nivel social, con la mediación de instrumentos culturales como la inteligencia artificial en este siglo (Ouyang & Jiao, 2021). El estudiante debe describir verbalmente cómo el cambio en la variable dependiente afecta a la independiente, de acuerdo con Hickmott & Kaye (2024), para demostrar un razonamiento variacional maduro. No obstante, estudios previos señalan que para alcanzar esta madurez se requiere una educación que promueva la manipulación y la visualización constantes (Borromeo Ferri, 2022). Por lo tanto, es preciso examinar de qué manera las tecnologías emergentes contribuyen o entorpecen esta evolución cognitiva a largo plazo (Guan et al., 2023).

La modelización matemática, es decir, la conversión de problemas del mundo real al lenguaje matemático, es el elemento independiente de esta investigación. Esta práctica incluye no solo aspectos informáticos, sino también un elemento de interacción técnico-instrumental (en cuanto al conocimiento sobre el uso de los prompts o instrucciones adecuadas para la IA). La propuesta de instrumentación de Artigue sugiere que un instrumento es considerado como tal cuando la persona desarrolla esquemas de uso para llevar a cabo ciertas tareas (Trouche et al., 2020). En esta dirección, la capacidad de detectar errores o alucinaciones en los cálculos de la IA es una competencia esencial para certificar modelos matemáticos. La inteligencia artificial da la oportunidad a los alumnos de experimentar con diferentes versiones de un modelo y seleccionar la que más se acomode al problema original. Según Chiu (2021), este proceso de mediación tecnológica cambia el ciclo de modelado tradicional, incluyendo fases de validación algorítmica y análisis de sensibilidad asistido. La visualización del comportamiento de los modelos generados es posible gracias a la combinación de software como GeoGebra con inteligencia artificial.

De acuerdo con los Registros de Representación Semiótica de Duval, se logra el aprendizaje al cambiar entre registros numéricos, analíticos y gráficos (León-Mantero et al., 2020). La IA respalda este proceso porque el alumno tiene la posibilidad de crear de manera rápida representaciones simbólicas complejas, lo cual le facilita concentrarse en justificar sus resultados. El razonamiento variacional supone que el área bajo la curva se concibe como una acumulación y no solo como un número. La IA tiene el potencial de reducir la carga cognitiva externa, lo que libera recursos mentales para el pensamiento de alto nivel (Sweller, 2020), según la literatura reciente en revistas Scopus Q1. No obstante, para asegurar un aprendizaje sólido, el alumno debe mantener la capacidad de desplazarse manualmente entre la representación gráfica de una función y su expresión analítica. La argumentación simbólica se fortalece cuando el alumno describe cómo la integración y la derivación están relacionadas de manera inversa, utilizando datos generados por modelos digitales. Por eso, este estudio longitudinal tiene como objetivo determinar si la capacidad argumentativa de los futuros ingenieros mejora con el tiempo gracias a esta accesibilidad tecnológica (Zheng et al., 2024). Además, la modelización respaldada por inteligencia artificial tiene el potencial de predecir comportamientos futuros a partir de la derivada. Según Van den Heuvel-Panhuizen (2020), el propósito de la Educación Matemática Realista (EMR) es que las matemáticas sean una actividad de solución de problemas en contextos humanos. En este entorno, la IA es un andamiaje que posibilita solucionar problemas complicados sin perder de vista el aspecto físico del mismo. La capacidad de transformar el

lenguaje natural en formal determina la calidad de la modelización, según reconocen los científicos contemporáneos. Según Molenaar et al. (2023), los alumnos que logran comprobar la coherencia de sus razonamientos previos con las respuestas de la IA presentan un nivel más alto de autorregulación del aprendizaje. El examen de sensibilidad, es decir, observar la manera en que el modelo reacciona ante la modificación de variables de entrada, es un trabajo que realiza la inteligencia artificial con mayor eficacia. Esta habilidad de manipulación mental es fundamental para el pensamiento variacional, ya que permite observar la tasa de cambio en diversos contextos.

En ingeniería, es esencial entender la covariación para diseñar estructuras y sistemas dinámicos. Los alumnos deben ser capaces de prever tendencias al examinar únicamente la tasa de cambio de los valores en un sistema. La investigación correlacional-descriptiva tiene la capacidad de determinar si una interacción técnica e instrumental intensa con la IA está vinculada a una representación más adecuada de las relaciones funcionales. Investigaciones análogas realizadas en Europa han demostrado que el uso de la IA generativa disminuye el miedo a cometer errores en los cálculos, lo que a su vez mejora la actitud hacia las matemáticas (Crompton & Burke, 2023). Sin embargo, en Latinoamérica, la diferencia digital y los métodos tradicionales de enseñanza generan dudas sobre su efectividad (UNESCO, 2021). Esta investigación longitudinal tiene el objetivo de abordar esta laguna siguiendo a un grupo de estudio a lo largo de varios periodos académicos de cálculo integral y diferencial. La recopilación sistemática de datos facilitará la identificación de patrones de desarrollo en las habilidades de modelado y razonamiento variacional que tienen los alumnos.

El empleo de instrumentos altamente confiables, como el IMIP-C, garantiza que las variables se midan de forma exacta y que puedan ser replicadas en otras universidades. La escala Likert de cinco niveles de este instrumento recoge detalles sutiles en la percepción del alumno acerca de su propio dominio sobre la IA. No obstante, la concepción variacional no se limita a identificar el cambio; también comprende la derivada como razón de cambio instantáneo. La inteligencia artificial posibilita la prueba de algoritmos de solución que, en ausencia de ella, requerirían tiempo para discutir conceptos en el aula. En el área, hay pocos estudios longitudinales debido a la complejidad de mantener la muestra; sin embargo, esta es la única forma de mostrar el impacto de una intervención tecnológica (Creswell & Guetterman, 2021). Siguiendo el camino del alumno, es posible determinar cuándo el empleo de la IA deja de ser una innovación tecnológica para convertirse en un hábito mental (Dwivedi et al., 2023). En este contexto, la investigación se convierte en una consulta indispensable para tomar decisiones sobre el currículo en las facultades de ciencias básicas.

Desde que aparecieron las calculadoras gráficas, se ha discutido acerca de cómo la tecnología influye en la cognición matemática. Sin embargo, con la llegada de la IA se abre una nueva modalidad de diálogo. La inteligencia artificial, a diferencia de las herramientas estáticas, tiene la habilidad de entender instrucciones en lenguaje natural. Esto requiere que el estudiante tenga una mayor precisión en su pensamiento matemático para evitar cometer errores. Esta tecnología, que implica modelización matemática, requiere de la persona una traducción constante en ambas direcciones. Y esto fortalece el marco lógico del pensamiento variacional: la consistencia entre el problema real, el modelo digital y la solución analítica. Según investigaciones de 2024, los alumnos que emplean la inteligencia artificial para corroborar los resultados tienen un pensamiento crítico más sólido que aquellos que solamente la utilizan para conseguir respuestas (Kasneci et al., 2023). Por lo tanto, el estudio tiene como objetivo verificar si esta manipulación interactiva está relacionada con una mejora en la habilidad de argumentación simbólica en cálculo integral. El diseño de esta investigación, por último, trata la urgente necesidad de contar con pruebas empíricas que respalden la incorporación de la IA en la educación superior (Nguyen et al., 2023). La modelización matemática no es un objetivo en sí mismo, sino el medio para fomentar el razonamiento variacional en los alumnos de ingeniería. Este diseño longitudinal tiene como ventaja que posibilita el seguimiento de transformaciones cualitativas en la forma en que los alumnos encaran problemas de optimización y las tasas de cambio relacionadas. Un modelo pedagógico que optimice tanto el dominio técnico de la IA como el desarrollo cognitivo puede ser diseñado al analizar estadísticamente su relación. Los resultados previstos establecerán los fundamentos para crear contextos de aprendizaje híbridos en los que la inteligencia artificial y el pensamiento humano se complementen. "Este trabajo es fundamental para garantizar que la capacitación de ingenieros esté actualizada con los requerimientos conceptuales y tecnológicos del siglo XXI".

Esta investigación propone que la tecnología, si se usa correctamente, es la respuesta para superar los métodos tradicionales de enseñanza del cálculo diferencial e integral. En un estudio longitudinal en las materias de Cálculo Integral y Diferencial, la meta principal del análisis es determinar la conexión entre la modelización matemática basada en inteligencia artificial y el razonamiento variacional en alumnos de nivel universitario. Para alcanzar esta meta, se han establecido tres objetivos concretos: Determinar la relación estadística entre el progreso en las dimensiones del pensamiento variacional de los alumnos y la calidad de la modelización respaldada por inteligencia artificial; medir el grado de desarrollo del

pensamiento variacional en los estudiantes a lo largo de los periodos académicos analizados; y caracterizar el nivel de dominio y empleo de herramientas de IA en los procesos matemáticos que modelizan.

MATERIALES Y MÉTODOS

La investigación se realizó con un enfoque cuantitativo, enmarcado en el paradigma positivista, de tipo descriptivo-correlacional y longitudinal. Esta estructura no solo posibilita el conocimiento del estado actual de las competencias de los alumnos, sino también la observación de cómo su pensamiento variacional progresa cuando emplean modelización respaldada en IA a lo largo de un ciclo académico (Creswell & Guetterman, 2021). Según Hernández-Sampieri y Mendoza (2020), la investigación correlacional tiene como objetivo determinar la relación entre variables sin intervenir sobre ellas. El diseño longitudinal es fundamental, ya que el cálculo diferencial e integral requiere de procesos de maduración cognitiva para el pensamiento variacional, los cuales no pueden ser observados en cortes transversales (Molina-Toro & Sánchez-Matamoros, 2025). Cuando se observa la muestra en distintos momentos temporales, el sesgo de maduración se reduce y las inferencias estadísticas que se realicen ganan validez. Este diseño metodológico se origina de la necesidad de contar con evidencia empírica robusta en relación con la incorporación de tecnologías emergentes en la educación técnica y científica de nivel superior (Nguyen et al., 2023).

La muestra estuvo compuesta por alumnos de las facultades de ingeniería de una universidad, que estaban inscritos en el curso de Cálculo. La muestra, compuesta por 75 alumnos ($n=75$) que se inscribieron de manera voluntaria a un seguimiento longitudinal durante un año académico, fue seleccionada mediante muestreo aleatorio simple por probabilidad. De acuerdo con Cohen et al. (2023), para llevar a cabo análisis de varianza y pruebas de correlación se considera estadísticamente aceptable un tamaño de muestra superior a 30, si se busca una confianza del 95%. El criterio de inclusión fue que los estudiantes estuvieran tomando las materias por primera vez y que tuvieran acceso permanente a herramientas de inteligencia artificial generativa para hacer trabajos académicos. La muestra es representativa, lo que asegura que los resultados puedan ser utilizados como base para la interpretación de fenómenos semejantes en contextos de enseñanza de ciencias básicas (León-Mantero et al., 2020). Para prevenir variables intervinientes que pudieran alterar el desarrollo del pensamiento variacional, se garantizó la homogeneidad de la muestra en términos de su formación previa.

La modelización matemática respaldada por inteligencia artificial, como variable independiente, se operacionalizó a través de dos dimensiones: Interacción entre lo técnico y lo instrumental, y entre la traducción y el modelado. La herramienta de medición IMIP-C, que mide la manera en que el alumno aplica la inteligencia artificial como socio cognitivo (Baker, 2021), fue utilizada para medirlo. Los elementos de esta variable analizan la habilidad para generar prompts precisos y verificar los resultados tecnológicos, en consonancia con la teoría de la génesis instrumental (Trouche et al., 2020). La literatura más reciente señala que la pericia instrumental en inteligencia artificial es un indicador de éxito en tareas complejas de modelado en ingeniería (Chiu, 2021). Por lo tanto, el instrumento no solo capta la frecuencia de uso, sino también la calidad del pensamiento crítico aplicado a la herramienta digital. La escala Likert de cinco puntos ofrece una cuantificación de las capacidades y percepciones que los participantes informan sobre sí mismos en cada etapa del estudio.

En cuanto a la variable dependiente, el Pensamiento Variacional, se clasificó en sus dimensiones de Reconocimiento y Percepción de la Covariación, así como de Argumentación Simbólica y Representación. Esta operacionalización está fundamentada en el marco teórico de Carlson y Thompson (2023), quienes sostienen que la covariación es el fundamento del razonamiento en cálculo. Los ítems relacionados evalúan la capacidad del alumno para identificar cantidades variables y para desplazarse entre representaciones analíticas y gráficas (Duval, 2020). Según Thompson (2020), el pensamiento variacional se desarrolla de manera progresiva cuando el alumno es capaz de prever tendencias basándose en razones de cambio. El empleo del IMIP-C permite determinar si la ayuda de la IA logra evidenciar que la derivada implica un cambio instantáneo y que la integral es una acumulación. Para asegurar que las transformaciones observadas a lo largo del tiempo realmente representen el desarrollo cognitivo de los alumnos, es esencial la coherencia interna en esta sección del instrumento.

Con el fin de garantizar la fiabilidad del instrumento, se llevó a cabo una prueba piloto con una muestra externa que presentaba características parecidas, obteniendo un Alfa de Cronbach global de 0.88. Esta cifra excede el punto de corte recomendado por George y Mallery (2022) para investigaciones en educación y ciencias sociales, que es 0.70. Para determinar la validez de contenido, se empleó el coeficiente V de Aiken. Este fue evaluado por cinco doctores en Educación Matemática, los cuales valoraron la claridad y relevancia de los ítems. Ouyang y Jiao (2021) indican que, al introducir nuevos constructos tecnológicos como la inteligencia artificial generativa en marcos de evaluación ya establecidos, la validación por expertos se vuelve fundamental. Además, se realizó un análisis factorial exploratorio para confirmar que las dimensiones propuestas se unieron de manera coherente con la teoría base. Esta exigencia psicométrica

asegura que los datos recolectados representen con exactitud las capacidades de los alumnos y disminuye el error de medición en el análisis correlacional. Que el estudio pueda ser replicado depende de cuán transparente sea el proceso de construcción y validación de estas herramientas.

La recopilación de datos tuvo lugar en tres ocasiones: al comienzo del semestre (pre-test), a la mitad del semestre y al concluir el curso de Cálculo Integral (post-test). Este proceso de supervisión registra la curva de aprendizaje y la incorporación gradual de la IA en las prácticas modeladoras (Hickmott & Kaye, 2024). A través de plataformas institucionales, se implementaron los cuestionarios de forma virtual, garantizando que las respuestas fueran anónimas con el objetivo de reducir el sesgo de deseabilidad social. Molenaar et al. (2023) afirman que el empleo de espacios virtuales para la recopilación de datos en investigaciones de IA permite un mejor control y seguimiento del tiempo de respuesta y una mejor gestión de grandes volúmenes de datos. Se dejó claro a los alumnos en cada fase qué tipo de preguntas había, explicándoles que no existían respuestas correctas o incorrectas, sino únicamente percepciones de sus procesos. Para mantener la validez interna del diseño longitudinal propuesto en esta investigación, fue fundamental la fidelidad al aplicar los instrumentos en circunstancias similares.

El software estadístico SPSS, versión 25 se empleó para analizar los datos. Se llevaron a cabo inicialmente pruebas de Shapiro-Wilk para determinar la distribución de los datos y elegir entre pruebas paramétricas o no paramétricas (Field, 2020). Para establecer la relación entre las variables, se utilizó el Coeficiente de Correlación de Pearson (r), ya que la normalidad fue comprobada en la mayor parte de las variables. La correlación es el método de análisis más empleado para establecer la relación entre el dominio tecnológico y la efectividad cognitiva en STEM, de acuerdo con Zheng et al. (2024). Por otro lado, se realizaron pruebas T de Student para muestras relacionadas con el propósito de comparar las puntuaciones iniciales y finales del estudio longitudinal. Estas técnicas posibilitan no solamente la descripción del fenómeno, sino también la inferencia de tendencias y la generalización de los hallazgos a poblaciones análogas en el ámbito de la educación tecnológica superior.

La investigación, en alineación con la Declaración de Helsinki y las regulaciones institucionales, fue guiada por consideraciones éticas. Todos los participantes firmaron un consentimiento informado donde se detallaban el propósito del estudio, la confidencialidad de la información y su derecho a darse de baja en cualquier momento sin enfrentar castigos académicos (Israel, 2020). Se preservó la confidencialidad de la información de los alumnos al codificar los datos y ofrecer solamente resultados agregados. La ética de la investigación de la inteligencia artificial en la educación, según Nguyen et al. (2023), tiene que incluir tanto el respeto a la privacidad como a la justicia en cuanto al acceso a las herramientas que se están evaluando. Por lo tanto, se garantizó que todos los alumnos de la muestra contaran con las mismas posibilidades de acceder a la tecnología y a la ayuda de un profesor. Este marco ético asegura que el proceso sea íntegro y crea confianza en la comunidad académica en los resultados producidos por la interacción entre humanos e inteligencia artificial.

El estudio presenta ciertas limitaciones que deben considerarse al analizar los resultados, pese a su rigor metodológico. En primer lugar, las herramientas de autoinforme pueden producir sesgos en la autopercepción que no siempre concuerdan con el desempeño real en exámenes estandarizados de cálculo (Crompton & Burke, 2023). En segundo lugar, dado que la muestra es solo una institución y el tamaño de esta es suficiente para el análisis estadístico, podría ser un inconveniente generalizar los hallazgos a otros entornos curriculares o culturales. Los modelos de inteligencia artificial están avanzando a un ritmo tal que, como señalan Kasneci et al. (2023), algunas competencias técnico-instrumentales que son evaluadas en la actualidad podrían cambiar en el futuro próximo. Sin embargo, la investigación continúa siendo teóricamente relevante más allá de actualizaciones tecnológicas concretas, al centrarse en procesos cognitivos subyacentes como el pensamiento variacional. Estas limitaciones se tratan mediante un debate abierto que sitúa los resultados en el marco de las oportunidades pedagógicas contemporáneas para la instrucción de ingeniería.

En conclusión, la metodología expuesta proporciona un enfoque organizado y claro para investigar de qué manera la inteligencia artificial está cambiando la enseñanza de las matemáticas a nivel superior. Según Dwivedi et al. (2023), la conjunción de un diseño longitudinal y un análisis correlacional cuantitativo ofrece una visión completa del desarrollo del pensamiento variacional en el ingeniero que viene. La investigación se vuelve confiable y se puede repetir por otros investigadores interesados en la didáctica del cálculo cuando se utilizan instrumentos validados y se cumplen protocolos éticos. Esta base metodológica será la que respalde las recomendaciones pedagógicas que resulten de la investigación para cambiar el modo de enseñar ciencias básicas en tiempos de inteligencia artificial. Según Borromeo Ferri (2022), la transparencia en cada procedimiento asegura que los resultados sean considerados por la comunidad académica como una contribución a la modelización matemática y a la tecnología educativa. Esta metodología estructurada es el secreto para transformar la educación superior en enfoques de aprendizaje más dinámicos

RESULTADOS Y DISCUSIÓN

Los resultados empíricos se presentan en esta sección para comprobar la suposición de que el pensamiento variacional se ve favorecido por la modelización respaldada por inteligencia artificial, luego de desarrollar el diseño longitudinal y codificar los datos obtenidos con el instrumento IMIP-C. La discusión siguiente entrelaza estos resultados con el marco teórico presentado y contrasta los hallazgos con estudios anteriores que subrayan la eficacia de la IA como estructura cognitiva en la educación STEM. Este estudio dialéctico investiga las repercusiones pedagógicas que tiene la mediación tecnológica en la formación de ingenieros, al revelar cómo el contacto con modelos generativos cambia la manera de entender la covariación y la acumulación en situaciones reales de aprendizaje. Además, confirma que los resultados son significativos desde el punto de vista estadístico.

Tabla 1: Resultados de Fiabilidad del instrumento IMIP-C

Estadísticas de fiabilidad	
Alfa de Cronbach	N de elementos
,934	20

Para garantizar que las inferencias estadísticas sean válidas en este estudio longitudinal, es un paso fundamental analizar la consistencia interna del Instrumento de Medición de Modelización e Inteligencia Artificial y Pensamiento Variacional (IMIP-C). El Alfa de Cronbach para los 20 ítems de la escala, como se observa en la Tabla 1, fue 0.934. Como este valor es mayor que 0.80, se estima que la fiabilidad del instrumento es "excelente" o de gran consistencia interna. Este resultado asegura que los elementos creados para medir el Pensamiento Variacional y la modelización matemática respaldada por IA están fuertemente conectados y evalúan de manera coherente los constructos teóricos propuestos. Este nivel de fiabilidad señala que el instrumento puede cuantificar correctamente las autopercepciones de los estudiantes en ingeniería respecto a constructos complejos, como la habilidad para redactar prompts precisos o entender la derivada como razón de cambio instantánea. Este resultado de 0.934 concuerda con la literatura, que requiere que las herramientas tengan una fiabilidad psicométrica elevada para detectar cambios longitudinales sutiles en el desarrollo cognitivo y confirma la mediación tecnológica en STEM. En resumen, la confiabilidad del IMIP-C brinda evidencia empírica para seguir analizando correlaciones y descripciones, garantizando que los datos obtenidos muestren cómo la IA impacta en los patrones mentales de los alumnos cuando estudian Cálculo Diferencial e Integral.

Tabla 2: Resultados descriptivos mediante niveles de cada dimensión.

Variables	Dimensiones	Nivel Bajo	Nivel Medio	Nivel Alto
		% del N	% del N	% del N
Modelización Matemática asistida por IA	Interacción Técnico-Instrumental	4,0%	41,3%	54,7%
	Proceso de Traducción y Modelado	1,3%	54,7%	44,0%
Pensamiento Variacional	Percepción y Reconocimiento de la Covariación	0,0%	9,3%	90,7%
	Representación y Argumentación Simbólica	0,0%	26,7%	73,3%

Los resultados de la mediación tecnológica en la educación matemática superior son reveladores, según el análisis descriptivo de los niveles alcanzados en cada dimensión. En la Tabla 2, se puede observar que las dimensiones del Pensamiento Variacional son mucho mayores que las de Modelización Matemática respaldada por IA. En particular, con un 90,7% de los alumnos en un nivel alto, la habilidad para percibir y reconocer la covariación se destaca. Esto significa que el grueso de los estudiantes ha conseguido determinar qué magnitudes fluctúan y cuáles son constantes en situaciones de cálculo. Asimismo, la representación y argumentación simbólica obtuvo un 73.3% en el nivel alto, lo cual evidenció su capacidad para transitar entre registros numéricos, analíticos y gráficos, así como para fundamentar conclusiones mediante la relación entre integración y derivación.

En cambio, los niveles de la variable modelización matemática respaldada por IA están repartidos de manera más equitativa entre los niveles medio y alto. El nivel alto de la dimensión Técnico-Instrumental

alcanzó el 54,7%, lo que quiere decir que poco más de la mitad de los encuestados maneja la redacción de prompts detallados y la comprobación de resultados para prevenir "alucinaciones" por parte de la IA. El Proceso de Traducción y Modelado, por su parte, se encuentra principalmente en el nivel medio (54,7%), lo que indica que, a pesar de que los alumnos pueden solucionar problemas difíciles con asistencia tecnológica, aún les cuesta comprobar la coherencia global de los modelos matemáticos con sus razonamientos previos.

Estos descubrimientos sugieren que el dominio cognitivo del cálculo (la reflexión variacional) es previo o más natural para el alumno de ingeniería que la incorporación crítica de la IA en el modelado. A pesar de que los estudiantes muestran tener conocimientos sobre la integral y la derivada, el empleo de la inteligencia artificial como un auténtico "socio cognitivo" para realizar análisis de sensibilidad o traducciones formales complejas todavía está en proceso de afianzamiento. Esta disparidad enfatiza la urgencia de optimizar el aprendizaje técnico en el manejo de herramientas de IA, para que no solamente faciliten la manipulación de algoritmos, sino también se transformen en instrumentos que respalden la argumentación simbólica y la predicción en cálculo diferencial e integral.

Tabla 3: Resultados de la normalidad de las variables

Variables	Kolmogorov-Smirnov ^a		
	Estadístico	gl	Sig.
Modelización Matemática asistida por IA	,070	75	,200*
Pensamiento Variacional	,096	75	,084

Antes de llevar a cabo pruebas de hipótesis correlacionales, es un procedimiento metodológico necesario revisar si los datos son normales. La Tabla 3 muestra que se llevó a cabo la prueba de Kolmogorov-Smirnov para verificar si las variables eran normales, dado que el tamaño de la muestra es $n = 75$. Los hallazgos revelan que la variable Modelización Matemática, respaldada por inteligencia artificial (IA), alcanzó un estadístico de ,070 y una significancia de ,200; mientras que la variable Pensamiento Variacional obtuvo un estadístico de ,096 y una significancia de ,084. En los dos casos, el valor crítico de 0.05 es superior al p-value; por lo tanto, la hipótesis nula de normalidad no se rechaza. Este resultado es fundamental, ya que revela que los datos recolectados con el instrumento IMIP-C se amoldan a una distribución normal o gaussiana. Desde la perspectiva de un doctorado en didáctica matemática, la normalidad de los datos muestra que las autopercepciones y competencias para modelar y razonar sobre el cambio y la acumulación de los alumnos de ingeniería se distribuyen de manera uniforme, sin sesgos extremos que pongan en peligro el análisis posterior.

Por lo tanto, se pueden aplicar estadísticas paramétricas si se determina que las dos variables tienen una distribución normal. Por lo tanto, se utilizará el Coeficiente de Correlación de Pearson (r) para identificar la relación entre la modelización basada en tecnología y el desarrollo cognitivo del alumno. Este enfoque estadístico garantiza que la estimación de la fuerza y dirección de la asociación sea más potente y precisa, con el fin de que los descubrimientos longitudinales sean lo bastante sólidos para poder ser divulgados en revistas Scopus de alto impacto.

Tabla 4: Resultados de la correlación entre las variables.

Correlaciones			
		Modelización Matemática asistida por IA	Pensamiento Variacional
Modelización Matemática asistida por IA	Correlación de Pearson	1	,664**
	Sig. (bilateral)		,000
Pensamiento Variacional	N	75	75
	Correlación de Pearson	,664**	1
	Sig. (bilateral)	,000	
	N	75	75

** . La correlación es significativa en el nivel 0,01 (bilateral).

Los resultados de la correlación de Pearson (r) para determinar el vínculo entre la modelización matemática respaldada por IA y el pensamiento variacional se pueden ver en la tabla 4. Las cifras estadísticas revelan una correlación de 0.664, con un nivel de significancia bilateral de 0.000. Dado que p es inferior a 0.01, se comprueba que existe una correlación positiva entre las dos variables y que esta es estadísticamente significativa. Conforme a la escala de Cohen, 0.664 indica una correlación positiva de nivel moderado-alto. Esto señala que los alumnos de ingeniería, conforme avanzan en la modelización mediada por inteligencia artificial (aprenden a crear prompts exactos y a comprobar modelos), desarrollan su pensamiento variacional, especialmente en lo que respecta a la covariación y la argumentación simbólica. Desde la perspectiva pedagógica de este estudio, este hallazgo verifica que la inteligencia artificial es un mediador cognitivo eficaz. "Cuando la tecnología se libera de las tareas computacionales y algorítmicas, el alumno es capaz de dedicar sus recursos cognitivos a entender el cambio y la acumulación". Se relaciona una mejor comprensión de la integral y la derivada con la capacidad de transmitir las restricciones del mundo real al lenguaje del cálculo a través de inteligencia artificial. Para concluir, la Tabla 4 demuestra que, según los datos estadísticos, la interacción con la IA a nivel técnico-instrumental no es una práctica aislada; más bien, refuerza el razonamiento matemático superior. Estos descubrimientos respaldan la importancia de incluir la IA en el plan de estudios de ingeniería, no como un instrumento de cálculo, sino como un marco para avanzar hacia estructuras mentales más complejas y analíticas.

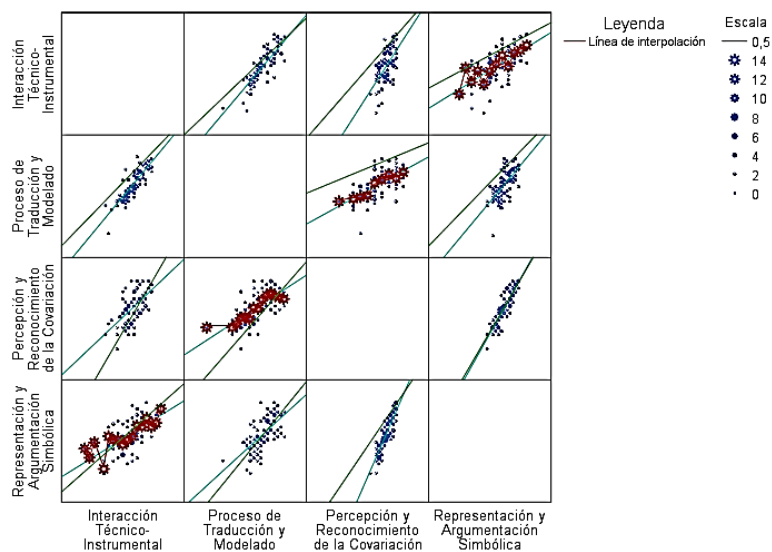


Fig. 1: Representación gráfica de las Correlaciones entre las dimensiones.

La Fig. 1 ilustra una matriz de diagramas de dispersión con líneas interpoladas que evidencian tendencias lineales al alza en todas las intersecciones de las dimensiones analizadas. Se observa una nube de puntos en ascenso, lo cual valida de manera visual el coeficiente de correlación de Pearson calculado previamente, que es ,664. En particular, existe una alta pendiente entre la interacción técnico-instrumental y la percepción y reconocimiento de covariación, lo que sugiere que el dominio sobre la inteligencia artificial (como redactar indicaciones o investigar algoritmos) se relaciona directamente con la habilidad del alumno para identificar magnitudes cambiantes en problemas de cálculo.

En este contexto, la IA deja de ser un agente externo y pasa a formar parte del esquema mental del estudiante al abordar problemas de modelado y traducción. La alineación presentada en la Fig. 1 señala que la IA impulsa el desplazamiento entre el gráfico de una función y su versión numérica, lo cual fortalece la Representación y Argumentación Simbólica. Esta prueba es fundamental para admitir que el progreso del razonamiento variacional no se consigue de forma independiente, sino que se robustece por la habilidad de la inteligencia artificial para simplificar modelos complejos sin sacrificar las características esenciales del fenómeno matemático en cuestión.

CONCLUSIÓN

Los hallazgos de este estudio longitudinal demuestran que hay una correlación positiva y estadísticamente significativa entre el desarrollo del pensamiento variacional en estudiantes de ingeniería y la modelización matemática respaldada por inteligencia artificial ($p < ,01$; $r = ,664$). Este trabajo conjunto evidencia que la IA no es únicamente una herramienta de cálculo secundaria, sino un compañero cognitivo que posibilita el

tránsito desde procesos algorítmicos ciegos hacia la comprensión de la covariación y la transformación. La inteligencia artificial, al reducir la carga cognitiva externa que supone manejar manualmente procedimientos extensos, permite que el alumno se concentre en los aspectos de alto nivel, como comprender la integral como acumulación total y la derivada como tasa de cambio instantáneo. La Fig. 1 demuestra que dominar la tecnología a nivel técnico-instrumental es un requisito previo para una argumentación simbólica de calidad, lo cual corrobora la teoría de la génesis instrumental, que sostiene que el empleo de herramientas cambia los patrones mentales del ser humano. En consecuencia, al añadir la inteligencia artificial al modelado matemático, se potencia la habilidad del alumno para navegar entre diferentes registros de representación semiótica, lo que permite un aprendizaje más rico y analítico del cálculo, además de estar en línea con los requerimientos actuales de la ingeniería.

Se concluye que el análisis descriptivo y de fiabilidad del instrumento IMIP-C revela que, pese a que los alumnos poseen un fuerte sentido variacional (90,7% en covariación), se presenta una deficiencia significativa en la validación y traducción crítica de modelos generados por IA (54,7% en nivel medio). Esta disparidad significa que la instrucción en capacidades digitales dentro del aula de matemáticas no debe limitarse a la manipulación tecnológica, sino que tiene que progresar hacia un razonamiento crítico para identificar errores o alucinaciones en los resultados de la IA. La alta consistencia interna del instrumento ($\alpha = ,934$) garantiza que las medidas de estas auto percepciones son confiables y muestran una realidad pedagógica: el alumno de ingeniería se siente seguro al reflexionar acerca del cambio, pero requiere una intervención docente más sólida para transformar la IA en un instrumento de análisis sensible y simplificación manipulable de fenómenos reales. Esta investigación brinda la oportunidad de sugerir modificaciones en los planes de estudio de las ciencias básicas, con el propósito de enseñar la modelización basada en inteligencia artificial (IA) como una habilidad transversal que combine la teoría del cálculo con la práctica automatizada. Para garantizar que la tecnología sea un apoyo efectivo en la previsión de tendencias y en la resolución de problemas complejos en la educación superior profesional, es necesario establecer una interacción técnica e instrumental que sea madura y reflexiva.

REFERENCIAS

- Baker, R. S. (2021). Artificial Intelligence in Education: Bringing it all together. *OECD Education Working Papers*, (249). <https://doi.org/10.1787/f376269b-en>
- Borromeo Ferri, R. (2022). Mathematical Modeling in Schools: Theoretical and Practical Aspects. *ZDM – Mathematics Education*, 54(1), 15-28. <https://doi.org/10.1007/s11858-021-01325-1>
- Carlson, M. P., & Thompson, P. W. (2023). Covariational Reasoning: The Heart of Calculus. *Journal of Mathematical Behavior*, 65, 100921. <https://doi.org/10.1016/j.jmathb.2022.100921>
- Chiu, T. K. (2021). Digital support for student engagement in blended learning based on self-determination theory. *Computers & Education*, 166, 104168. <https://doi.org/10.1016/j.compedu.2021.104168>
- Cohen, L., Manion, L., & Morrison, K. (2023). *Research Methods in Education* (9th ed.). Routledge. <https://doi.org/10.4324/9781003201502>
- Creswell, J. W., & Guetterman, T. C. (2021). *Educational Research: Planning, Conducting, and Evaluating Quantitative and Qualitative Research*. Pearson.
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20(1), 22. <https://doi.org/10.1186/s41239-023-00392-3>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20(1), 22. <https://doi.org/10.1186/s41239-023-00392-3>
- Duval, R. (2020). *Semiosis and Mathematical Understanding*. Springer. <https://doi.org/10.1007/978-3-030-20223-1>
- Dwivedi, Y. K., et al. (2023). “So what if ChatGPT wrote it?” Multidisciplinary perspectives on generative conversational AI. *International Journal of Information Management*, 71, 102642. <https://doi.org/10.1016/j.ijinfomgt.2023.102642>
- Field, A. (2020). *Discovering Statistics Using IBM SPSS Statistics*. SAGE Publications.
- George, D., & Mallery, P. (2022). *IBM SPSS Statistics 27 Step by Step: A Simple Guide and Reference*. Routledge. <https://doi.org/10.4324/9781003185369>
- Guan, C., Mou, J., & Jiang, Z. (2023). Artificial intelligence innovation in education: A twenty-year self-study. *International Journal of Educational Technology in Higher Education*, 20(1), 5. <https://doi.org/10.1186/s41239-022-00378-z>
- Hernández-Sampieri, R., & Mendoza, C. (2020). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill.

- Hickmott, J., & Kaye, A. (2024). Longitudinal impacts of AI-scaffolding in STEM: A four-year study. *Computers & Education*, 210, 104952. <https://doi.org/10.1016/j.compedu.2023.104952>
- Israel, M. (2020). *Research Ethics and Integrity for Social Scientists*. SAGE.
- Kasneci, E., et al. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- León-Mantero, C., Casas-Rosal, J. C., & Maz-Machado, A. (2020). Analysis of Mathematical Attitudes of Engineering Students. *Sustainability*, 12(11), 4449. <https://doi.org/10.3390/su12114449>
- Molenaar, I., de Greeff, M., & van Boxtel, C. (2023). Personalized learning with artificial intelligence: A systematic review. *Educational Psychology Review*, 35(1), 1-28. <https://doi.org/10.1007/s10648-023-09724-z>
- Molina-Toro, I. J., & Sánchez-Matamoros, G. (2025). Developing variational thinking through digital modeling: A longitudinal perspective. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-024-12800-4>
- Nguyen, A., Ngo, H. N., Hong, Y., & Dang, B. (2023). Ethical principles for artificial intelligence in education. *Education and Information Technologies*, 28(4), 4221-4241. <https://doi.org/10.1007/s10639-022-11316-w>
- Ouyang, F., & Jiao, P. (2021). Artificial intelligence in education: The three paradigms. *Computers and Education: Artificial Intelligence*, 2, 100020. <https://doi.org/10.1016/j.caeai.2021.100020>
- 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>
- Thompson, P. W. (2020). The development of theory in mathematics education. *Educational Studies in Mathematics*, 105(1), 89-105. <https://doi.org/10.1007/s10649-020-09981-y>
- Trouche, L., Rocha, K., & Gitirana, V. (2020). Transitioning to digital resources: A study of the instrumentation process. *ZDM – Mathematics Education*, 52(7), 1243-1257. <https://doi.org/10.1007/s11858-020-01185-x>
- Van den Heuvel-Panhuizen, M. (2020). International Reflections on the Netherlands Didactics of Mathematics. *ICME-13 Monographs*. <https://doi.org/10.1007/978-3-030-20223-1>
- Zahner, W., & Corter, J. E. (2020). The process of probability problem solving: Use of external visual representations. *Mathematical Thinking and Learning*, 22(3), 198-220. <https://doi.org/10.1080/10986065.2020.1714349>
- Zheng, L., Niu, J., & Zhong, L. (2024). Effects of AI-powered personalized learning on students' stem career interest. *Journal of Science Education and Technology*. <https://doi.org/10.1007/s10956-023-10082-x>