

INNOVACIÓN EN LA ENSEÑANZA DE LAS MATEMÁTICAS EN INGENIERÍA

**INTELIGENCIA ARTIFICIAL, ANDAMIAJE
COGNITIVO Y NUEVAS ESTRATEGIAS PARA EL
APRENDIZAJE DE LAS CIENCIAS BÁSICAS**

INNOVACIÓN EN LA ENSEÑANZA DE LAS MATEMÁTICAS EN INGENIERÍA

**INTELIGENCIA ARTIFICIAL, ANDAMIAJE
COGNITIVO Y NUEVAS ESTRATEGIAS PARA EL
APRENDIZAJE DE LAS CIENCIAS BÁSICAS**

AUTORES

BRITO ESCALANTE CAROLINA, CHIU LARA ROBERTO AGUSTÍN, ORTIZ MUÑIZ BENIGNO, VALENZUELA CASTILLO CARLOS MIGUEL, LEYVAROMERO MELVA JAMIE, VICHY CRUZ ANED MARÍA, HERRERA TRIANA JESÚS, RODRÍGUEZ MORENO CELIA ISABEL, LARA COLÓN RICARDO, ROMO RODRÍGUEZ PAMELA, ARCEO LUNA ANA ROSA, GARCÍA RUEDA ANA KAREN, VILLEGAS FONSECA LUIS ERNESTO, TREJO LORENZANA LAYDA COINTA, LARRAÑAGA JÁUREGUI ISIDRA IRENE, MERCADO HERRERA ALBA, HERNÁNDEZ MENDIOLA JESÚS ABENAMAR.

©RED IBEROAMERICANA DE ACADEMIAS DE INVESTIGACIÓN A.C. 2026



EDITA: RED IBEROAMERICANA DE ACADEMIAS DE INVESTIGACIÓN A.C.
DUBLÍN 34, FRACCIONAMIENTO MONTE MAGNO
C.P. 91190. XALAPA, VERACRUZ, MÉXICO.
CEL 2282386072
www.redibai.org
redibai@hotmail.com

ISBN: 978-607-5893-97-6



Sello editorial: Red Iberoamericana de Academias de Investigación, A.C.
(978-607-5893)
Primera Edición, Xalapa, Veracruz, México.
No. de ejemplares: 2
Presentación en medio electrónico digital
Formato PDF 5 MB
Fecha de aparición 04/09/2026
ISBN 978-607-5893-97-6

DICTAMEN EDITORIAL

La presente obra fue arbitrada y dictaminada en dos procesos; el primero, fue realizado por el **COMITÉ EDITORIAL RED IBEROAMERICANA DE ACADEMIAS DE INVESTIGACIÓN A.C.** con sede en México; que sometió a los capítulos incluidos en la obra a un proceso de dictaminación a doble ciego para constatar de forma exhaustiva la temática, pertinencia y calidad de los textos en relación a los fines y criterios académicos de la misma, cumpliendo así con la primera etapa del proceso editorial. El segundo proceso de dictaminación estuvo a cargo del **COMITÉ CIENTÍFICO RED IBEROAMERICANA DE ACADEMIAS DE INVESTIGACIÓN A.C.**; donde se seleccionaron expertos en el tema para la evaluación de los capítulos de la obra y se procedió con el sistema de dictaminación a doble ciego. Cabe señalar que previo al envío a los dictaminadores, todo trabajo fue sometido a una prueba de detección de plagio. Una vez concluido el arbitraje de forma ética y responsable y por acuerdo del Comité Editorial y Científico de la Red Iberoamericana de Academias de Investigación A.C. (REDIBAI), se dictamina que la obra **“INNOVACIÓN EN LA ENSEÑANZA DE LAS MATEMÁTICAS EN INGENIERÍA. INTELIGENCIA ARTIFICIAL, ANDAMIAJE COGNITIVO Y NUEVAS ESTRATEGIAS PARA EL APRENDIZAJE DE LAS CIENCIAS BÁSICAS”** cumple con la relevancia y originalidad temática, la contribución teórica y aportación científica, rigurosidad y calidad metodológica, actualidad de las fuentes que emplea, redacción, ortografía y calidad expositiva.

Dr. Daniel Armando Olivera Gómez

Director Editorial

Sello Editorial: Red Iberoamericana de Academias de Investigación, A.C.

(978-607-5893)

Dublín 34, Residencial Monte Magno

C.P. 91190. Xalapa, Veracruz, México.

Cel 2282386072

CERTIFICACIÓN EDITORIAL

RED IBEROAMERICANA DE ACADEMIAS DE INVESTIGACIÓN A.C. (REDIBAI) con sello editorial **No. 978-607-5893** otorgado por la Agencia Mexicana de ISBN, hace constar que el libro **“INNOVACIÓN EN LA ENSEÑANZA DE LAS MATEMÁTICAS EN INGENIERÍA. INTELIGENCIA ARTIFICIAL, ANDAMIAJE COGNITIVO Y NUEVAS ESTRATEGIAS PARA EL APRENDIZAJE DE LAS CIENCIAS BÁSICAS”** registrado con el **ISBN 978-607-5893-97-6** fue publicado por nuestro sello editorial con fecha de aparición del 04 de septiembre de 2026 cumpliendo con todos los requisitos de calidad científica y normalización que exige nuestra política editorial.

Fue evaluado por pares académicos externos y aprobado por nuestro Comité Editorial y Científico.

Todos los soportes concernientes a los procesos editoriales y de evaluación se encuentran bajo el poder Editorial de **RED IBEROAMERICANA DE ACADEMIAS DE INVESTIGACIÓN A.C. (REDIBAI)**, los cuales están a disposición de la comunidad académica interna y externa en el momento que se requieran.

La normativa editorial y repositorio se encuentran disponibles en la página **<http://www.redibai-myd.org>**

Doy fe.

Dr. Daniel Armando Olivera Gómez

Director Editorial

Sello Editorial: Red Iberoamericana de Academias de Investigación, A.C.
(978-607-5893)

Dublín 34, Residencial Monte Magno

C.P. 91190. Xalapa, Veracruz, México.

Cel 2282386072

ÍNDICE

INTRODUCCIÓN

1

**ANDAMIAJE SOCRÁTICO EN LA ELABORACIÓN DE
ACTIVIDADES DE APRENDIZAJE EN EJERCICIOS DE
APLICACIÓN DE CÁLCULO DIFERENCIAL**

2

Brito Escalante, Carolina

**USO DE LA INTELIGENCIA ARTIFICIAL PARA LA
SOLUCIÓN DE PROBLEMAS EN CÁLCULO VECTORIAL**

10

Chiu Lara, Roberto Agustín

**DE LOS SABERES PREVIOS A LOS ENTORNOS
INTELIGENTES: MITIGACIÓN DEL RIESGO ACADÉMICO
EN LA ENSEÑANZA DE LAS CIENCIAS BÁSICAS EN
INGENIERÍAS**

18

Ortiz Muñiz, Benigno

**INTELIGENCIA ARTIFICIAL EN CÁLCULO Y ÁLGEBRA
LINEAL: RECOMENDACIONES PARA UNA INTEGRACIÓN
DIDÁCTICA EN LA EDUCACIÓN SUPERIOR**

22

Valenzuela Castillo, Carlos Miguel

**APLICACIÓN DEL CÁLCULO DIFERENCIAL EN LAS
DIFERENTES ÁREAS DE LA INGENIERÍA**

31

Leyva Romero, Melva Jamie

Vichy Cruz, Aned María

Herrera Triana, Jesús

Rodríguez Moreno, Celia Isabel

**DEL RESULTADO DIRECTO AL ANDAMIAJE COGNITIVO:
USO DE LLMS COMO TUTORES SOCRÁTICOS EN LA
RESOLUCIÓN DE PROBLEMAS DE CIENCIAS BÁSICAS**

39

Lara Colón, Ricardo

Romo Rodríguez, Pamela

Arceo Luna, Ana Rosa

DE LA CONCEPTUALIZACIÓN FÍSICA A LA COMPRENSIÓN BIOLÓGICA:

LA INTELIGENCIA ARTIFICIAL COMO PUENTE

PEDAGÓGICO EN LAS CIENCIAS BÁSICAS

García Rueda, Ana Karen

49

REINGENIERÍA PEDAGÓGICA EN INVESTIGACIÓN DE OPERACIONES: TRANSFORMANDO EL APRENDIZAJE EN INGENIERÍA EN GESTIÓN EMPRESARIAL EN EL ITBOCA ...

Villegas Fonseca, Luis Ernesto

Trejo Lorenzana, Layda Cointa

55

ESTRATEGIAS DIDÁCTICAS MEDIADAS POR INTELIGENCIA ARTIFICIAL PARA EL APRENDIZAJE DE LAS APLICACIONES DE LA DERIVADA EN ESTUDIANTES DE NIVEL SUPERIOR DE INGENIERÍA: UNA REVISIÓN DOCUMENTAL CRÍTICA

Larrañaga Jáuregui, Isidra Irene

Mercado Herrera, Alba

61

ANÁLISIS ESTRUCTURAL: INTELIGENCIA ARTIFICIAL GENERATIVA PARA EL APRENDIZAJE DE LAS MATEMÁTICAS Y LA QUÍMICA EN ESTUDIANTES DE LA LICENCIATURA EN BIOLOGÍA

Hernández Mendiola, Jesús Abenamar

71

INNOVACIÓN EN LA ENSEÑANZA DE LAS MATEMÁTICAS EN INGENIERÍA

INTELIGENCIA ARTIFICIAL, ANDAMIAJE COGNITIVO Y NUEVAS ESTRATEGIAS PARA EL APRENDIZAJE DE LAS CIENCIAS BÁSICAS

Innovación en la Enseñanza de las Matemáticas en Ingeniería: Inteligencia Artificial, Andamiaje Cognitivo y Nuevas Estrategias para el Aprendizaje de las Ciencias Básicas es una obra colectiva que reúne experiencias, propuestas y reflexiones académicas de docentes del Tecnológico Nacional de México las cuales están orientadas a la transformación de los procesos de enseñanza y aprendizaje de las ciencias básicas en la educación superior.


Los capítulos que integran esta obra convergen en una problemática común: la necesidad de transitar de modelos tradicionales de enseñanza, centrados predominantemente en la transmisión y obtención de resultados, hacia estrategias que favorezcan la comprensión conceptual, el razonamiento matemático, la resolución de problemas, la autonomía del estudiante y la transferencia del conocimiento a situaciones propias de las diferentes áreas de la ingeniería y las ciencias.

Un eje fundamental de la obra es la incorporación crítica y didáctica de modelos de lenguaje (LLM), como recurso para apoyar el aprendizaje de las matemáticas, la química y otras ciencias básicas. Los trabajos analizan sus posibilidades como herramienta para la resolución de problemas, la retroalimentación, la tutoría socrática, la generación de explicaciones y el acompañamiento del estudiante.

Otro eje es el andamiaje cognitivo y socrático, entendido como una estrategia para conducir al estudiante desde sus conocimientos previos hacia niveles progresivamente mayores de comprensión y autonomía. Desde esta perspectiva, la tecnología no sustituye la intervención pedagógica del docente, sino que puede convertirse en un medio para formular preguntas, promover la reflexión, identificar errores conceptuales y favorecer procesos de razonamiento que trasciendan la obtención directa de una respuesta.

La obra también aborda la importancia de reconocer los saberes previos y el riesgo académico en las ciencias básicas, destacando la necesidad de identificar oportunamente las dificultades que presentan los estudiantes al incorporarse a la educación superior y diseñar estrategias de nivelación, acompañamiento y atención diferenciada. En este sentido, se propone una visión preventiva de la enseñanza que permita intervenir antes de que las deficiencias conceptuales se conviertan en factores de rezago o abandono académico.

Asimismo, los capítulos muestran el carácter transversal de las matemáticas y las ciencias básicas mediante el análisis de sus aplicaciones en diversos campos de la ingeniería y otras disciplinas, incluyendo el cálculo diferencial, cálculo vectorial, investigación de operaciones, física, biología y química. Su propósito final es fortalecer la formación matemática y científica de los futuros profesionales de la ingeniería mediante una integración equilibrada entre conocimiento disciplinar, intervención docente, andamiaje cognitivo e inteligencia artificial.



ANDAMIAJE SOCRÁTICO EN LA ELABORACIÓN DE ACTIVIDADES DE APRENDIZAJE EN EJERCICIOS DE APLICACIÓN DE CÁLCULO DIFERENCIAL

Brito Escalante, Carolina;
PTC TECNOM/Instituto Tecnológico de Boca del Río
carolinabrito@bdelrio.tecnm.mx

INTRODUCCIÓN

La enseñanza del cálculo diferencial en los programas de ingeniería enfrenta un desafío que va más allá de aprender las reglas de derivación: consiste en que el estudiante pueda aplicar ese conocimiento a la interpretación y la resolución de problemas específicos de su campo profesional. En Ingeniería en Gestión Empresarial, el cálculo diferencial es fundamental para analizar funciones de costo, ingreso y utilidad marginal, así como para optimizar recursos; en Ingeniería Mecánica, apoya el estudio de tasas de cambio, cinemática, resistencia de materiales y modelos de comportamiento físico. En ambos casos, el desafío para el docente no es solo enseñar a calcular una derivada, sino también a desarrollar el razonamiento que vincula el modelo matemático con la situación real que representa, y mantener el interés del estudiante por temas complejos en un momento en el que existen diversos distractores que pueden interferir en la asimilación del conocimiento.

La integración de la inteligencia artificial (IA) generativa en los entornos educativos permite al docente acceder a nuevas posibilidades para el acompañamiento personalizado, sin tener que ir de alumno en alumno aclarando dudas. Sin embargo, también plantea un riesgo pedagógico importante: el estudiante puede llegar a depender de la herramienta para el razonamiento, limitándose a obtener respuestas en lugar de desarrollar una comprensión conceptual. Por ello, este capítulo propone utilizar el andamiaje socrático como guía para diseñar actividades de aprendizaje mediadas por la IA. Con la finalidad de que la tecnología no reemplace el pensamiento del estudiante, sino que lo acompañe mediante preguntas progresivas, retroalimentación adaptada y una reducción paulatina del apoyo, en línea con la noción de zona de desarrollo próximo de Vygotsky (1978) y el modelo de tutoría de Wood et al. (1976).

El capítulo se organiza en las secciones convencionales de un trabajo académico: se presenta la justificación del tema, el objetivo que orienta la propuesta, el método documental empleado, el marco teórico que fundamenta el andamiaje socrático aplicado a la IA en la enseñanza del cálculo diferencial y, finalmente, las conclusiones y referencias, con la intención de ofrecer un insumo conceptual y práctico para docentes de ciencias básicas en programas de Ingeniería en Gestión Empresarial e Ingeniería Mecánica.

JUSTIFICACIÓN

Las ciencias básicas constituyen el cimiento sobre el cual se edifican las competencias técnicas de cualquier programa de ingeniería, y el cálculo diferencial ocupa un lugar central en dicho cimiento por su función instrumental en la modelación de fenómenos de cambio. Sin embargo, la literatura especializada documenta de manera reiterada bajos niveles de desempeño y altos índices de reprobación en los cursos introductorios de cálculo, así como dificultades del estudiantado para transferir los procedimientos algebraicos a la resolución de problemas contextualizados en la ingeniería (Báez et al., 2017).

En este panorama, Alcántara et al. (2024) reportan que, al implementar una estrategia didáctica que integra la inteligencia artificial en un enfoque activo de enseñanza-aprendizaje del cálculo diferencial para ingeniería, el grupo experimental mostró un mejor desempeño en la comprensión y el uso significativo de los conceptos matemáticos que el grupo de control. Los mismos autores señalan, con base en una revisión bibliográfica previa, que herramientas digitales como GeoGebra, Matlab o Derive han sido ampliamente documentadas en la enseñanza del cálculo diferencial, mientras que el uso pedagógicamente estructurado de la inteligencia artificial permanece como un campo poco explorado, lo que evidencia una oportunidad de investigación e innovación didáctica.

Esta oportunidad, no obstante, exige cautela. Bloom (1984) demostró que la tutoría individualizada puede elevar el rendimiento promedio de un estudiante muy por encima del alcanzado en la enseñanza grupal convencional, fenómeno conocido como el problema de las dos sigmas, cuya limitación histórica ha sido la imposibilidad económica de asignar un tutor humano a cada estudiante. Khan (2024) plantea que los tutores basados en IA generativa podrían acercar la enseñanza masiva a los beneficios de la tutoría personalizada, siempre que dicha tutoría reproduzca una interacción dialógica y no una mera provisión de respuestas. De ahí la pertinencia de anclar el diseño de actividades apoyadas en IA a un modelo pedagógico explícito —el andamiaje socrático— que preserve el esfuerzo cognitivo del estudiante y evite la sustitución del razonamiento propio por respuestas generadas automáticamente.

Finalmente, el enfoque diferenciado hacia la Ingeniería en Gestión Empresarial y la Ingeniería Mecánica se justifica porque, si bien ambas comparten el cálculo diferencial como asignatura de ciencias básicas, los ejercicios de aplicación que dan sentido profesional a dicho conocimiento difieren sustancialmente: unos se orientan a la optimización económica y financiera, y otros a la modelación de fenómenos físicos y mecánicos. Un andamiaje socrático mediado por IA que reconozca esta diferencia permite diseñar actividades de aprendizaje más pertinentes para cada perfil profesional.

OBJETIVO

Proponer un marco de andamiaje socrático para el diseño de actividades de aprendizaje mediadas por inteligencia artificial en la enseñanza de ejercicios de aplicación de cálculo diferencial, dirigido a estudiantes de Ingeniería en Gestión Empresarial e Ingeniería Mecánica.

Para orientar su desarrollo, se plantean los siguientes objetivos específicos:

Caracterizar los fundamentos teóricos del andamiaje educativo y del método socrático en su convergencia con la mediación de la inteligencia artificial.

Identificar las particularidades de los ejercicios de aplicación de cálculo diferencial pertinentes para la Ingeniería en Gestión Empresarial y la Ingeniería Mecánica.

Diseñar una estructura escalonada de actividades de aprendizaje —andamiaje socrático— para la resolución guiada de problemas de cálculo diferencial con apoyo de IA.

MÉTODO

El presente trabajo se desarrolló bajo un enfoque cualitativo de tipo documental y conceptual, propio de los capítulos de libro orientados a la construcción de propuestas didácticas fundamentadas en la literatura especializada, sin que ello implique una intervención empírica en el aula. El proceso se organizó en cuatro fases.

En la primera fase, de fundamentación teórica, se realizó una revisión de la literatura en bases de datos académicas como Google Scholar, Dialnet, Scielo, ERIC y repositorios de acceso abierto, empleando descriptores en español e inglés tales como “andamiaje”, “scaffolding”, “método socrático”, “tutoría con inteligencia artificial”, “cálculo diferencial en ingeniería” y “pensamiento variacional”. Se priorizaron fuentes con una relación directa entre los conceptos de andamiaje o mediación socrática y la enseñanza de las matemáticas o de las ciencias básicas en contextos de ingeniería.

En la segunda fase, de caracterización disciplinar, se analizaron los tipos de ejercicios de aplicación de cálculo diferencial reportados en la literatura para la Ingeniería en Gestión Empresarial (funciones de costo, ingreso, utilidad y optimización de recursos) y para la Ingeniería Mecánica (razones de cambio relacionadas, cinemática y análisis de esfuerzos), con el fin de identificar contextos de aplicación pertinentes para cada perfil.

En la tercera fase, de construcción de la propuesta, se diseñó una estructura de andamiaje socrático organizada en niveles progresivos de preguntas orientadoras, contrastando dicha estructura con los principios del modelo de tutoría de Wood et al. (1976) y con la noción de zona de desarrollo próximo de Vygotsky (1978), de modo que el apoyo brindado por la IA se ajuste al nivel de autonomía del estudiante y se retire gradualmente conforme este avanza.

En la cuarta fase, de contraste conceptual, la propuesta se confrontó con los hallazgos de estudios previos sobre el uso de la IA en la enseñanza del cálculo diferencial en ingeniería, con el propósito de verificar su coherencia y pertinencia antes de su presentación final en este capítulo.

MARCO TEÓRICO

El andamiaje educativo: origen y funciones

El concepto de andamiaje (scaffolding) fue acuñado por Wood, Bruner y Ross (1976) en su estudio sobre el papel de la tutoría en la resolución de problemas, donde describieron el andamiaje como el proceso mediante el cual un adulto o tutor controla temporalmente los elementos de una tarea que exceden la capacidad inicial del aprendiz, permitiéndole concentrarse únicamente en aquello que sí está en condiciones de resolver. Esta noción se articula estrechamente con la zona de desarrollo próximo formulada por Vygotsky (1978), entendida como la distancia entre lo que un aprendiz puede lograr de forma independiente y lo que puede alcanzar con la guía de alguien más experimentado. El principio pedagógico central del andamiaje es el desvanecimiento progresivo del apoyo: a medida que el estudiante gana autonomía, la asistencia se retira gradualmente hasta que este es capaz de resolver la tarea por sí mismo.

El método socrático como forma de mediación

El método socrático, basado en la mayéutica, consiste en guiar el pensamiento del interlocutor mediante preguntas sucesivas que lo llevan a examinar sus propios supuestos y a construir su propia comprensión, en lugar de recibir una respuesta ya elaborada. Aplicado a la mediación con inteligencia artificial, este método reorienta el uso de los modelos de lenguaje: en lugar de que la IA entregue directamente la solución de un ejercicio, la IA actúa formulando preguntas que exigen al estudiante explicitar su razonamiento, identificar variables, plantear hipótesis y verificar la coherencia de sus resultados. Esta perspectiva coincide con lo señalado en experiencias educativas recientes que han incorporado el diálogo socrático como componente central de tutores basados en IA generativa en distintas disciplinas, incluida la enseñanza de las matemáticas.

Convergencia entre andamiaje, método socrático e inteligencia artificial

La conjunción de ambos principios —andamiaje y mayéutica— da lugar a lo que en este capítulo se denomina andamiaje socrático: una forma de mediación en la que el apoyo temporal que brinda la IA no consiste en resolver la tarea, sino en formular preguntas calibradas al nivel de dificultad que enfrenta el estudiante, replicando la función del tutor descrita por Wood et al. (1976). El interés por este tipo de mediación se sustenta, además, en el llamado problema de las dos sigmas planteado por Bloom (1984), quien evidenció que la tutoría individualizada produce mejoras sustanciales en el desempeño en comparación con la enseñanza grupal convencional, aunque su escalamiento resultaba históricamente inviable por razones de costo. Khan (2024) sostiene que los tutores basados en IA generativa podrían acercar la enseñanza masiva a ese beneficio, en la medida en que se diseñen para sostener un diálogo pedagógico y no para despachar respuestas inmediatas. El valor del andamiaje socrático, en consecuencia, no reside en la tecnología en sí misma, sino en la estructura pedagógica que orienta su uso.

El cálculo diferencial en la formación de Ingeniería en Gestión Empresarial e Ingeniería Mecánica

El desarrollo del pensamiento variacional—la capacidad de interpretar, predecir y modelar fenómenos de cambio—constituye una competencia transversal que el cálculo diferencial debe fomentar en la formación de ingeniería (Báez et al., 2017). En la Ingeniería en Gestión Empresarial, esta competencia se traduce en el análisis de funciones de costo, ingreso y utilidad, la determinación de puntos óptimos de producción o precio, y la interpretación económica de la derivada como razón de cambio marginal. En la Ingeniería Mecánica, se expresa en el estudio de razones de cambio relacionadas, el análisis de velocidad y aceleración a partir de funciones de posición, y la aplicación de la derivada en problemas de optimización de diseño, resistencia de materiales y transferencia de energía.

Estudios recientes muestran que la incorporación de recursos digitales y de inteligencia artificial en la enseñanza del cálculo diferencial en ingeniería, cuando se acompaña de una estrategia didáctica explícita, favorece un mejor desempeño estudiantil (Alcántara et al., 2024), y que el apoyo de software especializado contribuye a la resolución de problemas de cálculo en poblaciones de ingeniería cuando se integra en una secuencia didáctica intencionada y no como recurso aislado (Carrasco-Barrionuevo et al., 2024). Estos hallazgos respaldan la pertinencia de diseñar actividades de aprendizaje que combinen los ejercicios de aplicación propios de cada perfil de ingeniería con una mediación de IA estructurada pedagógicamente.

Estructura propuesta de andamiaje socrático para actividades con IA

A partir de los referentes anteriores, se propone una secuencia de cuatro niveles de preguntas orientadoras que un docente puede incorporar en el diseño de actividades de aprendizaje mediadas por IA, aplicables a ejercicios de cálculo diferencial tanto en Ingeniería en Gestión Empresarial como en Ingeniería Mecánica.

Nivel 1 — Exploración del problema: la IA pregunta al estudiante qué variables identifica en el enunciado, qué representa cada una en el contexto empresarial o mecánico, y qué se le pide encontrar, sin ofrecer aún ninguna pista de solución.

Nivel 2 — Formulación del modelo: la IA orienta, mediante preguntas, la construcción de la función que representa la situación (de costo, utilidad, posición, energía, etc.), cuestionando al estudiante sobre las relaciones entre las variables antes de aceptar una expresión como válida.

Nivel 3 — Aplicación del procedimiento: la IA pregunta qué regla de derivación aplicar y por qué, invita a justificar cada paso y señala, mediante preguntas —no mediante correcciones directas—, cuando detecta una inconsistencia.

Nivel 4 — Interpretación y verificación: la IA solicita al estudiante interpretar el resultado obtenido en términos del problema original (¿qué significa este punto crítico para la utilidad de la empresa?, ¿qué representa esta razón de cambio para el sistema mecánico?) y verificar la coherencia de la respuesta con el contexto.

DESARROLLO

Caso práctico de ejemplo en un contexto empresarial (Costo-Utilidad)

Problema. Una empresa que fabrica mochilas estima que el costo de producir x unidades mensuales es: $C(x)=0.002x^2+15x+4000$ y que el precio de venta por unidad, si se producen y venden x mochilas, es $p(x)=60-0.01x$. La empresa quiere saber cuántas mochilas debe producir y vender al mes para maximizar su utilidad.

A continuación, se muestra un ejemplo de andamiaje generado por IA en el que se aplican los 4 niveles: exploración del problema, formulación del modelo, procedimiento e interpretación.

Nivel 1. Exploración del problema.

¿Qué datos puedes identificar en el enunciado?

De los datos que identificaste, ¿cuáles son variables y cuáles constantes?

¿Qué representa x en el problema?

¿Qué representan $C(x)$ y $p(x)$?

¿Qué te están pidiendo que encuentres exactamente? Un valor de x , un valor de utilidad o ambos.

Nivel 2. Formulación del modelo.

Si vendes x mochilas a un precio $p(x)$ cada una, ¿cómo se calcula el ingreso total $I(x)$?

¿Cómo se relacionan el ingreso, el costo y la utilidad?

Define la ecuación

¿Qué grado tiene el polinomio que obtuviste $U(x)$?

Nivel 3. Aplicación del procedimiento.

Para encontrar un máximo de $U(x)$, ¿qué condición debe cumplir la primera derivada en este punto?

¿Qué regla de derivación usarás para cada término de $U(x)$?

Escribe $U'(x)$

Al igualar $U'(x)=0$, ¿qué tipo de ecuación obtienes? ¿Qué método usarás para resolver?

El punto crítico es un máximo o un mínimo, ¿cómo se puede determinar?

Nivel 4. Interpretación.

¿Qué significa el valor de x que obtuviste?

¿El valor de x es un número de mochilas razonable?

Al calcular U en ese punto, ¿qué representa ese valor para la empresa?

Si la empresa produjera 50 unidades más que en tu respuesta, ¿la utilidad bajaría o aumentaría?

Los niveles de andamiaje mostrados permiten al docente involucrar al estudiante en la resolución de problemas, garantizando una comprensión efectiva de los temas. Al hacerle este tipo de preguntas, el docente puede medir qué tanto se comprendió el tema. Esto es muy distinto de solicitar una resolución. Por ello, tras este tipo de prácticas, se puede sugerir que, como docentes, debemos empezar a reformular las preguntas para obtener mejores respuestas.

El desvanecimiento del apoyo, principio central del andamiaje (Wood et al., 1976), se traduce en que la frecuencia e intensidad de las preguntas disminuyan conforme el estudiante demuestre dominio en actividades sucesivas, hasta que sea capaz de resolver ejercicios similares con una mediación mínima. Esta progresión evita que la IA se convierta en un sustituto del razonamiento del estudiante y, en cambio, la posiciona como un dispositivo de mediación pedagógica coherente con la tradición socrática y con el modelo vyotskiano de la zona de desarrollo próximo.

CONCLUSIONES


El andamiaje socrático ofrece un marco pedagógico pertinente para orientar el diseño de actividades de aprendizaje mediadas por la inteligencia artificial en la enseñanza del cálculo diferencial en los programas de ingeniería. Su valor no radica en la sofisticación tecnológica de las herramientas de IA, sino en la estructura de preguntas progresivas y en el principio de desvanecimiento del apoyo, que preservan el esfuerzo cognitivo del estudiante y evitan que la tecnología sustituya el razonamiento matemático que se busca desarrollar.

La diferenciación entre los ejercicios de aplicación propios de la Ingeniería en Gestión Empresarial y de la Ingeniería Mecánica resulta necesaria para que las actividades de aprendizaje conserven un sentido profesional: mientras la primera demanda el análisis de funciones económicas y la optimización de recursos, la segunda requiere la modelación de fenómenos físicos y mecánicos. En ambos casos, la estructura de cuatro niveles propuesta —exploración, formulación del modelo, aplicación del procedimiento e interpretación— permite adaptar el andamiaje socrático a los contextos específicos de cada perfil sin perder su coherencia pedagógica.

Finalmente, la evidencia revisada sugiere que la inteligencia artificial, cuando se integra en una estrategia didáctica explícita y no se utiliza como recurso aislado, contribuye positivamente al desempeño de los estudiantes de ingeniería en cálculo diferencial. No obstante, la propuesta aquí desarrollada tiene un carácter conceptual, por lo que se sugiere, como línea de trabajo futura, su validación empírica en cursos de ciencias básicas, así como su extensión a otras asignaturas del área, como el cálculo integral y las ecuaciones diferenciales, en las que el andamiaje socrático mediado por IA podría replicarse con ajustes propios de cada contenido.

REFERENCIAS

- Alcántara, W. M., Pérez González, O. L., & Bueno García, S. (2024). Estrategia didáctica basada en el uso de la inteligencia artificial para el Cálculo Diferencial en Ingeniería. *Educación Matemática Debate*, 8(14), 1–15.
- Báez, A., Martínez, Y., Pérez, O., & Pérez, R. (2017). Propuesta de tareas para el desarrollo del pensamiento variacional en estudiantes de ingeniería. *Formación Universitaria*, 10(3), 93–106.
- Carrasco-Barrionuevo, J. W., Allauca-Pancho, F. R., Mantilla-Cabrera, C. E., & Santillán-Lima, J. C. (2024). Estrategia didáctica para el aprendizaje de cálculo en estudiantes universitarios con el software Derive. *Revista de Ciencias Sociales*, 30(Número Especial 10).
- Khan, S. (2024). *Brave new words: How AI will revolutionize education (and why that is a good thing)*. Viking.
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press.
- Wood, D., Bruner, J. S., & Ross, G. (1976). The role of tutoring in problem solving. *Journal of Child Psychology and Psychiatry*, 17(2), 89–100.



USO DE LA INTELIGENCIA ARTIFICIAL PARA LA SOLUCIÓN DE PROBLEMAS EN CÁLCULO VECTORIAL

Chiu Lara, Roberto Agustín;
PA TECNOLÓGICO DE VERACRUZ
roberto.cl@veracruz.tecnm.mx

INTRODUCCIÓN

La evolución de la práctica docente en la educación superior ha transitado desde métodos tradicionales hacia una integración estratégica de tecnologías digitales. En la actualidad, la Inteligencia Artificial generativa emerge como una herramienta indispensable en procesos de evaluación, diseño instruccional y resolución de problemas.

Esta investigación explora el uso de la IA generativa en las actividades disciplinarias diarias dentro de la clase de Cálculo Vectorial. A través de un estudio con enfoque diagnóstico aplicado a docentes y estudiantes de la materia; se presenta un reporte preliminar que evalúa las necesidades críticas para su implementación. Los resultados indican que la IA generativa ofrece ventajas significativas, siempre que su adopción esté mediada por un uso ético, normado y metodológicamente correcto.

Con el pasar del tiempo, la tecnología ha evolucionado como una de las herramientas más influyentes en la actualidad. Decir que todo se puede realizar sin el uso de la tecnología, es demeritar el saber científico y las técnicas productivas empleadas, que se han desarrollado con el objetivo de crear nuevas herramientas, materiales, y una nueva forma de comprender la realidad.

Para el Instituto Mexicano de la Juventud, la tecnología se ha convertido en parte inseparable de la vida social, laboral y recreativa de las personas, sobre todo, de las y los jóvenes (Instituto Mexicano de la Juventud, 2017).

PROBLEMÁTICA

El desconocimiento acerca del uso de las herramientas tecnológicas actuales, influye en la decisión de adoptar estos mecanismos para innovar dentro del proceso educativo por parte de los docentes. En cambio, el alumnado está más familiarizado con las tendencias tecnológicas, de forma que se puede demostrar las habilidades existentes con el uso de estas. Sin embargo, aunque entre los estudiantes existe el uso de la Inteligencia Artificial generativa, no todos cuentan con los conocimientos básicos para el uso correcto de esta herramienta.

JUSTIFICACIÓN

El presente estudio aborda la identificación que esta problemática determina la necesidad de concientizar acerca del uso de la Inteligencia Artificial generativa, los resultados que pueden proporcionar, las ventajas y desventajas que brindan, principalmente, concientizar acerca de los aspectos éticos de su uso; fortaleciendo las habilidades y conocimientos técnicos en el uso de este tipo de herramientas en el ámbito educativo en el nivel superior dentro de la comunidad docente y estudiantil que imparte la materia de Cálculo Vectorial en el Instituto Tecnológico de Veracruz.

OBJETIVO

El objetivo de este estudio es identificar cuantos estudiantes y docentes utilizan la inteligencia artificial correctamente, cuan las estrategias que emplean los docentes para evaluar la información que los estudiantes, y que tan familiarizados se encuentran docentes y estudiantes acerca del uso y redacción de PROMPTS para la Inteligencia Artificial Generativa.

MÉTODO

Este estudio se llevará a cabo una investigación documental, además de realizar una encuesta acerca del conocimiento y uso de la Inteligencia Artificial generativa, su uso como herramienta de trabajo y aplicaciones en sus actividades académicas, tomando como muestra a un grupo de docentes de las academias de Ciencias Básicas y un grupo selecto de estudiantes de sus respectivos grupos.

MARCO TEÓRICO

La Inteligencia Artificial es una de las herramientas tecnológicas que ha evolucionado con el paso del tiempo desde su desarrollo inicial. Alan Turing, en su artículo Computing Machinery and Intelligence, sentó las bases para futuros debates de la naturaleza de las maquinas pensantes y cómo se podría medir su inteligencia a través del juego de la imitación (Turing, 1950).

En la actualidad, la Inteligencia Artificial generativa se ha convertido en una de las bases principales para obtener información. Sin embargo, eso conlleva a la validación de la información generada, con el objetivo de fomentar la ética y la responsabilidad del uso de la IA generativa.

La Tabla 1 lista brevemente la historia de la Inteligencia Artificial generativa que se ha destacado en la historia.

Tabla 1 Hitos y evolución de la inteligencia artificial generativa.

Año	Hito	Desarrollo
1960s	Primeros pasos	Se desarrollaron los primeros chatbots, el más destacado fue ELIZA, la cual utilizaba procesamiento de lenguaje natural basado en reglas.
1990-2000s	Fundaciones	La potencia de cómputo y el aumento de datos, permitieron la evolución de algoritmos de aprendizaje.
2010s	Aprendizaje profundo y redes generativas	Ian Goodfellow introdujo las redes generativas adversarias (GAN), permitiendo a dos redes neuronales competir para crear contenido realista.
2017	Revolución "Transformer"	Google Brain publica "Attention is All You Need", introduciendo la arquitectura "transformer", fundamental para los modelos de lenguaje moderno.
2019-2021	Large Language Model (LLM)	OpenAI lanza GPT-2 y GPT-3, demostrando la capacidad de generar texto coherente a gran escala.
2022-actualidad	Era comercial	El lanzamiento de ChatGPT de OpenAI hizo la IA generativa accesible al público. Le siguieron modelos de difusión para imágenes como DALL-E.

Fuente: elaboración propia.

El desconocimiento acerca del uso de las herramientas tecnológicas actuales, influye en la decisión de adoptar estos mecanismos para innovar dentro del proceso educativo por parte de los docentes. En cambio, el alumnado está más familiarizado con las tendencias tecnológicas, de forma que se puede demostrar las habilidades existentes con el uso de estas. Sin embargo, aunque entre los estudiantes existe el uso de la Inteligencia Artificial generativa, no todos cuentan con los conocimientos básicos para el uso correcto de esta herramienta.

La Inteligencia Artificial (IA) proporciona el potencial necesario para abordar algunos de los desafíos mayores de la educación actual, innovar las prácticas de enseñanza y aprendizaje y acelerar el progreso para la consecución del ODS 4. La UNESCO se compromete a apoyar a los Estados Miembros para que saquen provecho del potencial de las tecnologías de la IA con miras a la consecución la Agenda de Educación 2030, al tiempo que vela por que su aplicación en contextos educativos responda a los principios básicos de inclusión y equidad.

En el marco del Consenso de Beijing, la UNESCO ha elaborado la publicación Inteligencia artificial: guía para las personas a cargo de formular políticas, para fomentar la preparación de los responsables de formular políticas educativas en materia de inteligencia artificial. Su objetivo es favorecer la comprensión compartida de las oportunidades y desafíos que la IA proporciona a la educación, así como sus implicaciones para las competencias básicas necesarias en la era de la IA. La UNESCO también publicó Marcos de competencias en materia de IA de la UNESCO para estudiantes y docentes con el fin de orientar a los países a la hora de ayudar a los estudiantes y docentes a comprender el potencial y los riesgos de la IA (UNESCO, 2022).

La implementación de la Inteligencia Artificial en el sector educativo, presenta retos de gran importancia. Como menciona Suárez Estavillo (2025), la formación adecuada de los educadores es crucial para la integración efectiva de la IA. Sin embargo, la aceptación de este tipo de tecnología no solo se posibilita con aspectos como la formación académica; por el contrario, depende de factores sociales, culturales e ideológicos. La representación social que se tiene sobre estas tecnologías, a menudo influenciada por el cine, la literatura y los medios de comunicación, puede generar desconfianza y resistencia entre educadores y estudiantes.

Una de las ventajas que Santillán (2025) encuentra en el uso de la IA en la educación es el ser una herramienta que acompañe el proceso de estudio de los alumnos, como si fuera una tutoría, ya que los estudiantes pueden usarla para resolver las guías de estudio, recibir respuestas en tiempo real e ir puliendo información sobre un tema en particular.

Otra de las ventajas que se puede encontrar en el uso de la IA en la educación, es que esta tecnología permite personalizar el tipo de aprendizaje del estudiante. Ya que una vez que el docente logra identificar el estilo de aprendizaje del estudiante, este puede recomendar actividades, ejercicios o métodos de estudio, con el objetivo que el estudiante logre aprender de una manera mas eficiente.

Sin embargo, existen retos que aún hay que considerar para la implementación del uso de la IA en la educación.

Dentro de los retos que se pueden considerar, Santillán (2025) define dos que pueden ser críticos sobre el uso de la Inteligencia Artificial: todavía hay mucho miedo y desconocimiento de qué es y cómo funciona; y la idea que circula en el ambiente es que va a suplir muchos trabajos, entre ellos el de los profesores y profesoras. Otra limitante para el acceso a la Inteligencia Artificial, es que no todos tienen acceso a ella.

Un punto muy cuestionado sobre el uso de la Inteligencia Artificial en la educación, es que existe el temor que el estudiante desarrolle menos capacidades cognitivas, de memoria, de aprendizaje, niveles de pensamiento crítico y pensamiento lógico.

Conforme uno va conociendo cualquier tipo de tecnología va identificando tanto los beneficios como algunas consecuencias no deseadas, y en el caso de la Inteligencia Artificial una de ellas sería que los conocimientos que se generen en el salón de clases se queden en la superficialidad o que ni siquiera se construyan.

Lo importante es que el uso de la Inteligencia Artificial permita a los estudiantes y docentes poder desarrollarse, lograr incrementar las capacidades de estudio, y que actúe como una guía para generar conocimientos.

Una de las características de la Inteligencia Artificial generativa, es el uso correcto de prompts. Santiago (2024) define el prompt como un texto o instrucción que se utiliza para que una herramienta basada en un LLM proporcione una respuesta.

Un LLM (por su siglas en inglés, Large Language Model o Gran Modelo de Lenguaje) son una categoría de modelos de aprendizaje profundo entrenados con inmensas cantidades de datos, lo que los hace capaces de comprender y generar lenguaje natural y otros tipos de contenido para realizar una amplia gama de tareas. Los LLM se basan en un tipo de arquitectura de redes neuronales llamada transformador que se destaca en el manejo de secuencias de palabras y la captura de patrones en el texto (Stryker, 2025).

Los prompts pueden categorizarse en tres tipos: Zero-shot, One-shot, Few-shot. La Tabla 2 muestra los tipos de prompts y ejemplos de uso.

Tabla 2 Tipos de prompts, diferencias y usos

Prompt	Descripción	Ejemplo de uso
Zero-shot	Instrucción directa. La IA responde basándose en su entrenamiento general.	Escribe un eslogan creativo para una cafetería orgánica.
One-shot	Se le proporciona a la IA una muestra del resultado que se desea junto con la instrucción. Se le enseña el formato, tono o estilo que se requiere.	Clasifica las emociones de los clientes.Ejemplo: 'El producto llegó roto y me urge' -> Negativo.Texto a clasificar: 'Excelente servicio, llegó muy rápido' ->
Few-shot	Se proporcionan dos o mas ejemplos que definen un patron a seguir. Es una técnica que se utiliza para tareas complejas, ya que reduce las probabilidades de que la IA se equivoque.	Extrae el nombre del producto y el precio del siguiente texto. Sigue este formato: [Producto, Precio].Texto 1: 'Compré un monitor Samsung en \$200' -> [Monitor Samsung, \$200]Texto 2: 'Ayer vi una laptop Dell a \$800' -> [Laptop Dell, \$800]Texto 3: 'Quiero cambiar mi vieja televisión por esta nueva LG de \$500' ->

Fuente: elaboración propia.

Sin embargo, existen otros tipos de prompts que pueden complementar al funcionamiento de la IA generativa, tales como: prompts comparativos, secuenciales, argumentales, condicionales, meta-prompts, etc.

La deficiencia en el uso de prompts, hace que la implementación de la IA generativa en la educación pueda ser confuso. Esto puede deberse al tipo de resultado esperado no es el que se necesita. A la hora de elaborar un prompt, es necesario considerar ciertos principios para redactarlos. Entre los más importantes están el contexto, la claridad, la especificidad y el lenguaje objetivo. Estos criterios ayudan a estructurar la petición de forma que el modelo entienda exactamente qué se espera (Santiago, 2024).

DESARROLLO

Cálculo Vectorial es una de las materias del departamento de Ciencias Básicas, donde aproximadamente el 20% del contenido es teórico, el 80% restante se basa en cuestiones prácticas y gráficas. Sin embargo, existe la necesidad de realizar operaciones mas avanzadas de forma mas rápidas y eficientes, con capacidad de retroalimentar posibles cambios dentro de las funciones, así como tener la capacidad de graficar los resultados que se obtienen.

La Tabla 3 muestra la cantidad de personas encuestadas, cuantos de ellas utilizan la Inteligencia Artificial generativa y cuantos aún no la utilizan.

Tabla 3 Cantidad de encuestados que utilizan la inteligencia artificial


Respuesta	Cantidad	Docentes	Estudiantes
Sí	40	2	38
No	14	4	10
Total	54		

Fuente: elaboración propia.

Aunque los valores obtenidos por la encuesta muestran una tendencia favorable para el uso de la Inteligencia Artificial generativa, la cantidad de docentes que no la usan como una herramienta académica, supera la expectativa esperada de docentes que utilizan la tecnología. En comparación con la cantidad de estudiantes, que han comenzado a adoptar la Inteligencia Artificial generativa como una herramienta de apoyo para la realización de sus actividades escolares, tales como investigaciones, ejercicios, proyectos, etc.

Sin embargo, un factor importante se centra en el uso de los prompts. El conocimiento y la redacción de estos, ha influido en la decisión de implementar el uso de la Inteligencia Artificial generativa para las actividades de clases. La Figura 1 muestra la gráfica de la cantidad de estudiantes y docentes sobre el conocimiento del uso del prompt en la Inteligencia Artificial generativa.

Figura 1 Gráfica de encuestados sobre conocimiento del prompt de IA




Fuente: elaboración propia.

Al evaluar los resultados que se obtienen acerca del conocimiento sobre el uso de los prompts en la Inteligencia Artificial generativa, la tendencia muestra que existe un amplio desconocimiento sobre la función de los prompts, en comparación con los que sí saben la función de estos, aun cuando en ambos casos, ya han utilizado la Inteligencia Artificial generativa.

El análisis al conjunto de respuestas positivas de quienes ya han utilizado la Inteligencia Artificial generativa y tienen el conocimiento sobre el uso de los prompts, muestra un deficiente uso correcto de estos para el uso correcto de la Inteligencia Artificial generativa. La Figura 2 muestra el déficit de conocimiento en el uso correcto de la Inteligencia Artificial generativa de manera correcta para obtener las ventajas que esta herramienta puede otorgar.

Figura 2 Gráfica de encuestados que usan y redactan correctamente prompts de IA



Fuente: elaboración propia.

CONCLUSIONES

Un desafío principal acerca del uso de la Inteligencia Artificial se enfoca en la ética y en la enseñanza al estudiante acerca del uso responsable de este tipo de herramientas. Esto incluye en reconocer que la información es valiosa, por lo que se debe tener mucho cuidado al momento de compartirla con cualquier herramienta tecnológica y digital.

La falta de capacitación hacia el personal docente en el uso de la Inteligencia Artificial generativa, impide que se pueda innovar en el proceso educativo dentro del aula, ya que el docente es quien se encarga de transmitir el conocimiento hacia los estudiantes. Además, la falta de interés por parte de los estudiantes de aprender a utilizar de mejor manera esta herramienta, conlleva a que el uso de la Inteligencia Artificial generativa no sea de la forma correcta, desaprovechando los beneficios que brinda.

Otro de los desafíos que se pueden encontrar, se encuentra en la mejora de condiciones en la infraestructura en distintas regiones del país, esto con la finalidad que los estudiantes puedan acceder de forma fácil al uso de este tipo de herramientas, con la finalidad de no ampliar las brechas educativas.

REFERENCIAS

- Instituto Mexicano de la Juventud. (01 de agosto de 2017). La importancia de la tecnología para las juventudes. Obtenido de <https://www.gob.mx/imjuve/articulos/la-importancia-de-la-tecnologia-para-las-juventudes>
- Santiago, A. (29 de octubre de 2024). Guía para el uso académico de la inteligencia artificial: Diseño de prompts. Obtenido de <https://uned.libguides.com/c.php?g=723100&p=5327924>
- Santillán, M. L. (01 de diciembre de 2025). Grandes desafíos del uso de la IA en la escuela. Obtenido de <https://ciencia.unam.mx/leer/1633/grandes-desafios-del-uso-de-la-ia-en-la-escuela->
- Stryker, C. (26 de noviembre de 2025). What are large language models (LLMs)? Obtenido de IBM Think: <https://www.ibm.com/mx-es/think/topics/large-language-models>
- Suárez Estavillo, U. (2025). La inteligencia artificial en la educación: ¿transformación o infoxicación? Un análisis crítico de la nueva frontera educativa. SintAxis, 69-88.
- Turing, A. (1950). Computing Machinery and Intelligence. Mind, 433-460.
- UNESCO. (02 de septiembre de 2022). Artificial intelligence in education. Obtenido de <https://www.unesco.org/en/digital-education/artificial-intelligence>

**DE LOS SABERES PREVIOS
A LOS ENTORNOS
INTELIGENTES: MITIGACIÓN
DEL RIESGO ACADÉMICO
EN LA ENSEÑANZA DE LAS
CIENCIAS BÁSICAS EN
INGENIERÍAS**

Ortiz Muñoz, Benigno;
PTC TecNM /Instituto Tecnológico de Boca del Río
benigno.om@bdelrio.tecnm.mx

INTRODUCCIÓN

Históricamente la enseñanza de las ciencias básicas en programas académicos de Ingeniería ha enfrentado diversas problemáticas, de manera particular en la enseñanza del cálculo diferencial e integral. Materias tradicionalmente catalogadas como “díficiles” concentran altos índices de reprobación, rezago y riesgo de deserción estudiantil (Parra Sánchez et al., 2023). Esta problemática no responde exclusivamente a la complejidad intrínseca de las materias, sino a una brecha estructural de ingreso: la heterogeneidad y el déficit en los saberes previos de álgebra, trigonometría y geometría analítica con los que arriba el estudiantado proveniente de la educación media (Parra Sánchez et al., 2023; Silva et al., 2024). Sin embargo en las Instituciones de Educación Superior la enseñanza ha tratado de ser homogenizada, lo que ha llevado a un modelo poco flexible que no considera las diferencias en el estudiantado.

La tecnología educativa y la Inteligencia Artificial (IA) están obligando a que se lleven a cabo cambios estructurales en la forma de enseñanza, encaminados a generar espacios flexibles y a que se implementen tutorías mediadas por IA acordes a la dinámica del pensamiento matemático del estudiante (Pinto-Figueroa, 2026; Quiroz Rosas, 2023). El Consejo Nacional de Profesores de Matemáticas (NCTM, por sus siglas en inglés) de Estados Unidos de América establece que la implementación de la IA en la educación superior no debe ser automatizada, sino que debe ser una estrategia pedagógica que contemple un diagnóstico inicial con la personalización de los recursos didácticos de tal modo que se permita mitigar el riesgo académico (NCTM, 2024) entendido como la condición en la que un estudiante se puede encontrar para no acreditar una materia, tener rezago en su trayectorio escolar o inclusive desertar de sus estudios. Por lo anterior, se propone un modelo metodológico (DEME) para la transición gradual desde el diagnóstico (saberes previos) hacia el diseño e implementación de entornos de aprendizaje inteligentes para las ciencias básicas en programas académicos de ingenierías. La propuesta metodológica articula la caracterización de perfiles cognitivos, el uso de recursos educativos abiertos y la mediación docente experta como eje rector para neutralizar sesgos tecnológicos y generar el desarrollo de un pensamiento analítico-crítico en la educación superior universitaria.

MODELO PROPUESTO

El modelo (DEME) está estructurado en cuatro etapas operativas: a) Diagnóstico, b) Ecosistema, c) Mediación y d) Evaluación.

La primera dimensión analítica del diseño metodológico establece la operacionalización de las variables de entrada a través de un diagnóstico. Es por ello, que la primera etapa es el diagnóstico multidimensional de saberes previos y perfiles cognitivos, considerando el diseño y aplicación de instrumentos de entrada enfocados en competencias instrumentales críticas específicamente en álgebra superior, geometría analítica y trigonometría, y la integración del modelo de estilos de aprendizaje de Felder y Silverman; con ello se genera una matriz analítica de vulnerabilidad que visibiliza las brechas del estudiantado antes de abordar la formalización de los conceptos abstractos del cálculo.

En la segunda etapa, Ecosistema, se propone utilizar sistemas de inteligencia artificial (IA) y aprendizaje automático (machine learning) permitiendo la creación de un ecosistema inteligente y personalización de recursos (Cosquillo et al., 2025; Guishca et al., 2024), donde las actividades se centran en la configuración de los perfiles de vulnerabilidad y estilos cognitivos en sistemas de tutores inteligentes (ALEKS, Knewton, por ejemplo) que permiten la selección y adecuación de Recursos Educativos Abiertos (REA), permitiendo transitar hacia aplicaciones de la ingeniería.

El diseño metodológico debe integrar los lineamientos éticos y pedagógicos del Consejo Nacional de Profesores de Matemáticas (NCTM, 2024). Al existir un riesgo de sesgo, la propuesta establece en su tercera etapa, la mediación docente y mitigación de sesgos, donde el docente universitario asume un rol activo de supervisión y curación de contenidos validando el rigor matemático de los contenidos sugeridos por la IA. En esta mediación docente, la actividad pedagógica se dirige al entendimiento del error del estudiante, por lo que se transforma en la meta a resolver, de tal modo que se permita construir el nuevo conocimiento, relacionándolo con los saberes previos del estudiantado.

La última etapa es la evaluación formativa y el seguimiento. En esta cuarta etapa se sugiere implementar retroalimentación en periodos de tiempo pequeños mediante la interacción directa del alumnado con los sistemas de tutores inteligentes, respaldados por un seguimiento institucional continuo de diferentes indicadores, tales como: deserción y aprobación. En conjunto, esta integración ofrece una ruta sistemática para evaluar la eficacia real de la personalización frente a la no acreditación, el rezago y la deserción en la formación de futuros ingenieros.

CONCLUSIONES


La transición desde los saberes previos hacia los entornos inteligentes no debe ser una adopción instrumental o superficial de software educativo, sino un cambio en el paradigma educativo encaminado a la personalización. La identificación de las áreas de mejora en el estudiantado y de los estilos cognitivos resulta de importancia para disminuir el riesgo académico en la educación superior.

El uso de sistemas con inteligencia artificial y aprendizaje automático (machine learning) permite la generación de rutas de aprendizaje flexibles. La automatización de la selección de Recursos Educativos Abiertos (REA) y la solución de problemas de aplicación permiten que la formación sea dinámica acorde al estudiantado.

Los sistemas tutoriales inteligentes deben ser regulados y monitoreados por profesorado con experiencia en cada una de las materias, por lo que la labor del docente se libera de carga operativa y se debe centrar en el desarrollo del pensamiento analítico y crítico necesario para la formación en ingenierías.

REFERENCIAS

- Cosquillo Chida, J. L., López Becerra, E., Cepeda Robalino, Á. G., Tzaquimbio Peña, P. W., y Maliza Cruz, W. I. (2025). Gamificación e inteligencia artificial en la Enseñanza de Matemáticas: Estrategias Innovadoras para el Desarrollo del Pensamiento Lógico en Educación. *Revista Iberoamericana de la Educación*, 9(2): 141-166. <http://www.revista-iberoamericana.org/index.php/es>
- Guishca Ayala, L. A., Cárdenas Pila, V. N., Yanchaluiza Guachi, V. D. L. Á., Jiménez Poveda, F. E., Carrillo Lloacana, B. D., Castro Pérez, A. A., y Guevara Albarracín, E. S. (2024). Integración de la inteligencia artificial en la enseñanza de matemáticas: un enfoque personalizado para mejorar el aprendizaje. *Ciencia Latina Revista Científica Multidisciplinar*, 8(6): 10417-10435. https://doi.org/10.37811/cl_rcm.v8i6.15719
- National Council of Teachers of Mathematics (NCTM). (2024). Artificial Intelligence and Mathematics Teaching: A Position of the National Council of Teachers of Mathematics. NCTM Position Statement. <https://www.nctm.org>
- Parra Sánchez, J. S., Torres Pardo, I. D., y Martínez de Meriño, C. Y. (2023). Personalización de recursos para la enseñanza de matemáticas universitarias usando inteligencia artificial. *Revista Interamericana de Investigación, Educación y Pedagogía*, 16(1): 319-340. <https://doi.org/10.15332/25005421.7904>
- Pinto-Figueroa, M. C. (2026). Inteligencia artificial y transformación de los procesos de enseñanza matemática. *Episteme Koinonía: Revista Electrónica de Ciencias de la Educación, Humanidades, Artes y Bellas Artes*, 9(17): 306-328. <https://doi.org/10.35381/e.k.v9i17.4917>
- Quiroz Rosas, V. (2023). Aplicaciones de Inteligencia Artificial Aliadas en la Enseñanza de las Matemáticas. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4): 10547-10563. https://doi.org/10.37811/cl_rcm.v7i4.8070
- Silva, M., Correa, R., y Mc-Guire, P. (2024). Metodologías Activas con Inteligencia Artificial y su relación con la enseñanza de la matemática en la educación superior en Chile. Estado del arte. *Revista Iberoamericana de Tecnología en Educación y Educación en Tecnología*, (37): 20-29. <https://doi.org/10.24215/18509959.37.e2>
- Villena Atoche, C. A., Calsin Berríos, W., Espinoza Gaona, D. I., y Rengifo Osorio, J. A. (2024). Aplicación de la inteligencia artificial en la resolución de problemas matemáticos en el nivel universitario. *Revista Social Fronteriza*, 4(5): e458. [https://doi.org/10.59814/resofro.2024.4\(5\)e458](https://doi.org/10.59814/resofro.2024.4(5)e458)



INTELIGENCIA ARTIFICIAL EN CÁLCULO Y ÁLGEBRA LINEAL: RECOMENDACIONES PARA UNA INTEGRACIÓN DIDÁCTICA EN LA EDUCACIÓN SUPERIOR

Valenzuela Castillo, Carlos Miguel;
PA TECNM /Instituto Tecnológico de Boca del Río
carlosvalenzuela@bdelrio.tecnm.mx

INTRODUCCIÓN

La inteligencia artificial (IA) ha experimentado un desarrollo acelerado en los últimos años, transformando diversos ámbitos, entre ellos la educación superior. Las herramientas de IA generativa permiten responder preguntas, resolver problemas, generar explicaciones y proporcionar retroalimentación en tiempo real, lo que ha impulsado su incorporación en los procesos de enseñanza y aprendizaje. En áreas como el Cálculo Diferencial, el Cálculo Integral y el Álgebra Lineal, estas tecnologías ofrecen oportunidades para enriquecer las estrategias didácticas y promover experiencias de aprendizaje más dinámicas, personalizadas e interactivas.

Sin embargo, su integración también plantea desafíos. Muchos docentes aún desconocen sus posibilidades pedagógicas o muestran incertidumbre respecto a su uso en el aula, limitando el aprovechamiento de una herramienta que puede favorecer la comprensión de conceptos complejos y el aprendizaje autónomo. Además, la literatura señala riesgos relacionados con la dependencia tecnológica, la confiabilidad de las respuestas generadas y la integridad académica. Por ello, es fundamental que su incorporación esté guiada por criterios pedagógicos que fortalezcan el razonamiento y las competencias matemáticas de los estudiantes.

En este contexto, surge la siguiente pregunta de investigación: ¿cuáles son las buenas prácticas recomendadas por la literatura científica para integrar la inteligencia artificial en la enseñanza universitaria del Cálculo Diferencial, el Cálculo Integral y el Álgebra Lineal? Responder a esta interrogante permitirá identificar estrategias que faciliten una adopción informada y responsable de estas tecnologías por parte del profesorado.

El objetivo de este trabajo es identificar y analizar las principales recomendaciones y buenas prácticas reportadas en la literatura científica para la integración didáctica de la IA en estas asignaturas. Para ello, se realizó una investigación documental de enfoque cualitativo basada en la revisión y análisis de publicaciones científicas especializadas en inteligencia artificial aplicada a la educación matemática. Los hallazgos se sintetizan en un conjunto de recomendaciones orientadas a facilitar su incorporación en la práctica docente universitaria.

PROBLEMÁTICA

A pesar del creciente desarrollo de herramientas de inteligencia artificial aplicadas a la educación, muchos docentes universitarios aún desconocen cómo incorporarlas de manera efectiva en la enseñanza de asignaturas como Cálculo Diferencial, Cálculo Integral y Álgebra Lineal. Esta falta de familiarización limita el aprovechamiento de su potencial para fortalecer el aprendizaje, al tiempo que genera incertidumbre sobre su uso pedagógico, la confiabilidad de sus respuestas y su impacto en el desarrollo del razonamiento matemático y la integridad académica. En este contexto, resulta necesario identificar y difundir las buenas prácticas respaldadas por la literatura científica que orienten una integración didáctica responsable de la inteligencia artificial en la educación superior.

OBJETIVOS

Objetivo general

Identificar y analizar las buenas prácticas reportadas en la literatura científica para la integración didáctica de la inteligencia artificial en la enseñanza del Cálculo Diferencial, el Cálculo Integral y el Álgebra Lineal en la educación superior, con el propósito de promover su uso responsable y favorecer la familiarización de los docentes universitarios con estas herramientas.

Objetivos específicos

1. Analizar las principales aplicaciones de la inteligencia artificial en la enseñanza del Cálculo Diferencial, el Cálculo Integral y el Álgebra Lineal reportadas en la literatura científica.
2. Identificar los beneficios, desafíos y consideraciones pedagógicas asociados con el uso de la inteligencia artificial en la educación matemática universitaria.
3. Sintetizar las recomendaciones y buenas prácticas propuestas por las investigaciones revisadas para orientar a los docentes en la integración didáctica de la inteligencia artificial en su práctica educativa.

MÉTODO

El presente trabajo se desarrolló bajo un enfoque cualitativo mediante una investigación documental de carácter descriptivo. La información se obtuvo a partir de la revisión de artículos científicos relacionados con el uso de la inteligencia artificial en la educación superior, con énfasis en su aplicación en la enseñanza de las matemáticas, particularmente en las asignaturas de Cálculo Diferencial, Cálculo Integral y Álgebra Lineal. Los documentos analizados constituyeron la fuente principal de información para identificar las tendencias actuales, aplicaciones, beneficios, limitaciones y recomendaciones sobre la integración de la inteligencia artificial en los procesos de enseñanza y aprendizaje.

El proceso metodológico consistió en la lectura, análisis y comparación de los artículos seleccionados, extrayendo la información más relevante en función del objetivo de la investigación. Posteriormente, los hallazgos fueron organizados en categorías temáticas para identificar las principales buenas prácticas propuestas por los diferentes autores respecto al uso didáctico de la inteligencia artificial en el contexto universitario. Finalmente, se realizó una síntesis de la información recopilada con el propósito de presentar recomendaciones dirigidas a docentes de educación superior que imparten las asignaturas de Cálculo Diferencial, Cálculo Integral y Álgebra Lineal.

MARCO TEÓRICO

Inteligencia artificial y su evolución en la educación superior

La inteligencia artificial (IA) ha adquirido una presencia creciente en la educación superior debido a su capacidad para procesar información, automatizar tareas y adaptar recursos educativos a las necesidades de los estudiantes. Su evolución ha permitido el desarrollo de sistemas de tutoría inteligente, asistentes virtuales, plataformas de aprendizaje adaptativo y herramientas de generación de contenidos que apoyan tanto la enseñanza como el aprendizaje.

Diversos estudios señalan que la IA ha transformado los entornos educativos al ofrecer experiencias de aprendizaje más personalizadas, flexibles e interactivas. En el ámbito universitario, estas tecnologías facilitan la retroalimentación inmediata, el seguimiento del progreso académico y la adaptación de los materiales de estudio según el nivel de desempeño de cada estudiante. Asimismo, la IA contribuye a optimizar ciertas tareas docentes, permitiendo que el profesorado dedique más tiempo a actividades de acompañamiento y orientación pedagógica.

No obstante, la incorporación de la inteligencia artificial en la educación superior también ha generado debates relacionados con la ética, la privacidad de los datos, la dependencia tecnológica y los cambios en el papel del docente. Por ello, la literatura coincide en que estas herramientas deben concebirse como recursos de apoyo al proceso educativo y no como sustitutos de la interacción humana ni del trabajo pedagógico del profesor.

Inteligencia artificial generativa como herramienta para la enseñanza y el aprendizaje de las matemáticas

La inteligencia artificial generativa representa una de las aplicaciones más recientes y difundidas de la IA en el ámbito educativo. Herramientas como ChatGPT, Copilot, Gemini, Wolfram Alpha y Symbolab permiten generar explicaciones, responder preguntas, resolver ejercicios y proporcionar ejemplos adaptados a diferentes niveles de complejidad.

En la enseñanza de las matemáticas, estas herramientas ofrecen ventajas importantes al facilitar la comprensión de conceptos abstractos mediante explicaciones paso a paso, ejemplos contextualizados y retroalimentación inmediata. Además, favorecen el aprendizaje autónomo al permitir que los estudiantes consulten dudas fuera del horario de clase y exploren distintos procedimientos de solución.

La literatura revisada destaca que la efectividad de estas herramientas depende en gran medida de la calidad de las preguntas formuladas por los usuarios y de la capacidad para analizar críticamente las respuestas obtenidas. En consecuencia, diversos autores recomiendan promover una alfabetización en inteligencia artificial que permita a docentes y estudiantes utilizar estas tecnologías de manera reflexiva y responsable.

Aplicaciones de la inteligencia artificial en la enseñanza del Cálculo Diferencial, Cálculo Integral y Álgebra Lineal

Las investigaciones analizadas muestran múltiples aplicaciones de la inteligencia artificial en la enseñanza de asignaturas matemáticas universitarias. En Cálculo Diferencial y Cálculo Integral destacan herramientas capaces de resolver límites, derivadas e integrales, presentar procedimientos detallados y generar representaciones gráficas que facilitan la interpretación de los resultados.

Un ejemplo relevante es el uso de chatbots educativos implementados en entornos como Google Colab, los cuales integran cálculo simbólico, visualización gráfica e interacción conversacional para favorecer la comprensión conceptual de temas complejos. Estos sistemas permiten a los estudiantes comparar representaciones algebraicas y gráficas, fortaleciendo la construcción de significados matemáticos.

En Álgebra Lineal, diversos estudios reportan resultados favorables mediante el uso de MATLAB combinado con herramientas de inteligencia artificial. La integración de estas tecnologías ha permitido relacionar conceptos abstractos, como matrices, sistemas de ecuaciones y espacios vectoriales, con problemas reales de ingeniería. Los resultados muestran mejoras en el rendimiento académico, la participación estudiantil y el aprendizaje colaborativo.

Asimismo, plataformas como Symbolab y Wolfram Alpha han demostrado utilidad para apoyar la resolución de ejercicios y el estudio independiente, proporcionando procedimientos detallados que facilitan la comprensión de los conceptos matemáticos involucrados.

Beneficios, desafíos y consideraciones éticas del uso de la inteligencia artificial en la educación matemática

Los estudios revisados coinciden en señalar que la inteligencia artificial aporta diversos beneficios a la educación matemática. Entre los más relevantes destacan la personalización del aprendizaje, la retroalimentación inmediata, el incremento de la motivación estudiantil, el fortalecimiento de la autonomía y la mejora del rendimiento académico.

Además, estas herramientas permiten adaptar actividades y recursos al ritmo de aprendizaje de cada estudiante, favoreciendo la atención a la diversidad y el desarrollo de competencias digitales cada vez más demandadas en contextos profesionales.

Sin embargo, la literatura también identifica desafíos importantes. Entre ellos se encuentran la dependencia excesiva de la tecnología, el riesgo de aprendizaje superficial, la disminución del razonamiento matemático cuando las herramientas se utilizan únicamente para obtener respuestas y la posibilidad de errores o imprecisiones en los resultados generados por los sistemas de IA.

Desde una perspectiva ética, los principales retos se relacionan con la integridad académica, la privacidad de los datos, los sesgos algorítmicos y la equidad en el acceso a los recursos tecnológicos. En consecuencia, los autores enfatizan la necesidad de establecer lineamientos institucionales y estrategias pedagógicas que promuevan un uso responsable, crítico y transparente de la inteligencia artificial.

Buenas prácticas para la integración didáctica de la inteligencia artificial en la enseñanza universitaria de las matemáticas

A partir de la literatura analizada, es posible identificar un conjunto de buenas prácticas para la integración de la inteligencia artificial en la enseñanza universitaria de las matemáticas.

En primer lugar, se recomienda utilizar la IA como herramienta complementaria y no como sustituto de la actividad docente. El profesor continúa desempeñando un papel fundamental como mediador, orientador y diseñador de experiencias de aprendizaje.

En segundo lugar, las actividades deben promover el razonamiento matemático, la argumentación y la reflexión crítica. Para ello, la IA puede emplearse para generar preguntas, ejemplos, representaciones gráficas y explicaciones alternativas que faciliten la comprensión conceptual.

Asimismo, resulta conveniente combinar múltiples formas de representación matemática, integrando expresiones simbólicas, gráficas y explicaciones textuales. Esta estrategia favorece la comprensión profunda de conceptos complejos y fortalece la capacidad de los estudiantes para establecer conexiones entre diferentes registros de representación.

Otra recomendación consiste en diseñar actividades contextualizadas que relacionen los contenidos matemáticos con situaciones reales o problemas propios de la ingeniería. La evidencia muestra que esta práctica incrementa la motivación y favorece el aprendizaje significativo.

Finalmente, la literatura destaca la importancia de la capacitación continua del profesorado en competencias digitales e inteligencia artificial, así como la necesidad de promover principios éticos relacionados con la transparencia, la responsabilidad académica y el uso crítico de la tecnología.

RESULTADOS

La revisión documental realizada permitió identificar que la inteligencia artificial se ha consolidado como una herramienta con un importante potencial para apoyar la enseñanza y el aprendizaje de las matemáticas en la educación superior. Los estudios analizados coinciden en que herramientas como ChatGPT, Copilot, Wolfram Alpha, Symbolab y MATLAB favorecen la comprensión de conceptos matemáticos complejos mediante explicaciones personalizadas, resolución paso a paso de ejercicios, generación de representaciones gráficas y retroalimentación inmediata.

Uno de los hallazgos más relevantes es que la IA contribuye a la personalización del aprendizaje, ya que permite adaptar explicaciones, ejemplos y actividades al ritmo y nivel de conocimiento de cada estudiante. Esta característica resulta particularmente útil en asignaturas como Cálculo Diferencial, Cálculo Integral y Álgebra Lineal, donde suelen existir diferencias significativas en los conocimientos previos y en la capacidad de razonamiento matemático del alumnado.

La literatura también destaca que la combinación de inteligencia artificial con herramientas de visualización matemática fortalece la comprensión conceptual. En temas relacionados con límites, derivadas, integrales y espacios vectoriales, los estudiantes logran establecer conexiones más sólidas entre las representaciones algebraicas, gráficas y numéricas cuando utilizan plataformas que integran cálculo simbólico y representación visual.

Otro resultado importante es que diversas investigaciones reportan mejoras en el rendimiento académico y en la motivación de los estudiantes cuando la IA se incorpora mediante estrategias didácticas estructuradas. Los estudios experimentales revisados muestran incrementos en los niveles de aprobación y en la comprensión de contenidos matemáticos, especialmente cuando estas tecnologías se utilizan como complemento de la intervención docente y no como sustituto de ella.

Asimismo, se identificó que las experiencias más exitosas coinciden en promover metodologías activas de aprendizaje. Entre las estrategias reportadas se encuentran la resolución guiada de problemas, el aprendizaje colaborativo, la modelación matemática de situaciones reales, el uso de chatbots educativos como mediadores tecnológicos y la integración de recursos de inteligencia artificial en actividades de análisis, interpretación y argumentación matemática.

Sin embargo, la revisión también permitió identificar diversos desafíos asociados al uso de la inteligencia artificial en la educación matemática universitaria. Entre los principales se encuentran la dependencia tecnológica, la posibilidad de obtener respuestas incorrectas o incompletas, la reducción del esfuerzo cognitivo cuando las herramientas se utilizan únicamente para obtener respuestas rápidas y los riesgos relacionados con la integridad académica. Además, varios autores señalan la necesidad de fortalecer la formación docente y reducir las brechas de acceso tecnológico para garantizar una implementación equitativa de estas herramientas.

A partir del análisis de los documentos revisados, se identificaron las siguientes buenas prácticas para la integración didáctica de la inteligencia artificial en la enseñanza universitaria de las matemáticas:

- Utilizar la IA como herramienta de apoyo y no como sustituto del docente.
- Promover el razonamiento matemático mediante preguntas, explicaciones y análisis de resultados.
- Integrar representaciones simbólicas, gráficas y numéricas para favorecer la comprensión conceptual.
- Diseñar actividades contextualizadas que relacionen los contenidos matemáticos con problemas reales.
- Fomentar el aprendizaje autónomo acompañado de orientación y supervisión docente.
- Desarrollar competencias digitales e informacionales en estudiantes y profesores.
- Establecer criterios éticos para el uso responsable de las herramientas de inteligencia artificial.
- Evaluar periódicamente el impacto de estas tecnologías en el aprendizaje y el desarrollo de competencias matemáticas.

CONCLUSIONES

La revisión de la literatura científica permitió identificar que la inteligencia artificial ofrece un conjunto de herramientas con un elevado potencial para enriquecer la enseñanza del Cálculo Diferencial, el Cálculo Integral y el Álgebra Lineal en la educación superior. Sus principales aportaciones se relacionan con la personalización del aprendizaje, la disponibilidad de retroalimentación inmediata, la generación de representaciones múltiples y el fortalecimiento de la autonomía de los estudiantes.

Los estudios analizados muestran que la integración de la IA puede contribuir a mejorar la comprensión de conceptos matemáticos complejos y favorecer el rendimiento académico cuando su utilización forma parte de estrategias didácticas planificadas y orientadas por el docente. En este sentido, la evidencia revisada coincide en que la tecnología por sí sola no garantiza mejores resultados educativos, sino que su efectividad depende de la calidad de las actividades de aprendizaje y de la mediación pedagógica que acompañe su implementación.

Asimismo, la investigación permitió constatar que existen riesgos asociados a su uso indiscriminado, entre ellos la dependencia tecnológica, la disminución del pensamiento crítico, la confiabilidad variable de algunas respuestas y los desafíos relacionados con la integridad académica. Por ello, resulta indispensable promover una cultura de uso ético, crítico y responsable de estas herramientas tanto en estudiantes como en docentes.

Finalmente, las buenas prácticas identificadas sugieren que la inteligencia artificial debe incorporarse como un recurso complementario que favorezca la exploración, la reflexión y el razonamiento matemático. Su integración efectiva requiere capacitación docente continua, diseño de actividades centradas en el aprendizaje activo y una evaluación permanente de su impacto educativo. Bajo estas condiciones, la inteligencia artificial puede convertirse en un aliado significativo para fortalecer la enseñanza y el aprendizaje de las matemáticas en la educación superior.

REFERENCIAS

- Aguilar-Rodríguez, A., Rivera-García, P., Cervantes-Sandoval, A., & Perales-Avila, A. (2024). Artificial intelligence as a resource for teaching mathematics: Integral calculus as a specific case. *LatIA*, 2(96). <https://doi.org/10.62486/latia202496>
- Holmes, W., Bialik, M., & Fadel, C. (2019). Artificial intelligence in education: Promises and implications for teaching and learning. Center for Curriculum Redesign.
- Labadze, L., Grigolia, M., & Machaidze, L. (2023). Role of AI chatbots in education: Systematic literature review. *International Journal of Educational Technology in Higher Education*, 20, 56. <https://doi.org/10.1186/s41239-023-00426-1>
- Lagla, E., Molina, M., Sandoval, A., & Corrales, E. (2024). Integración de la inteligencia artificial como herramienta didáctica interactiva para el mejoramiento de los procesos de enseñanza en matemáticas: Un enfoque basado en el aprendizaje personalizado y adaptativo. *Polo del Conocimiento*, 9(9), 1272-1291. <https://doi.org/10.23857/pc.v9i9.7994>
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson.
- Moral-Sánchez, S. N., Ruiz Rey, F. J., & Cebrián-de-la-Serna, M. (2025). Analysis of artificial intelligence chatbots and satisfaction for learning in mathematics education. *International Journal of Educational Research and Innovation*.
- Núñez, J., Ávila, J., Ávila, L., & Cuecuecha, L. (2024). Empleo de la inteligencia artificial para resolver problemas matemáticos en el ámbito de la educación superior. *Reincisol*, 3(6), 3415-3433. <https://doi.org/10.59282/reincisol>
- Pérez, A. (2025). Impacto transformador de la inteligencia artificial en el razonamiento matemático: Implicaciones, avances y desafíos. *Revista Ingenium*, 3(1), 71-81.
- Quiroz, V. (2023). Aplicaciones de inteligencia artificial aliadas en la enseñanza de las matemáticas. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 7454-7467. https://doi.org/10.37811/cl_rcm.v7i4.7498
- Rodríguez, M., Leaño, A., Cervera, L., Toledo, P., & Majo, H. (2025). Inteligencia artificial en la educación: Revisión sistemática de su impacto, formación y consideraciones éticas. *Tribunal. Revista en Ciencias de la Educación y Ciencias Jurídicas*, 5(12), 467-486.
- Rojas Maldonado, E. R. (2025). Personalización del aprendizaje del concepto de límite mediante redes neuronales y visualización interactiva en Google Colab. *Revista Dilemas Contemporáneos: Educación, Política y Valores*, 12(3), 1-18. <https://doi.org/10.46377/dilemas.v12i3.4600>

- Rojas Maldonado, E. R. (2026). Propuesta metodológica de un chatbot educativo para el cálculo simbólico y gráfico de límites: Implicaciones para la educación matemática. *Revista Dilemas Contemporáneos: Educación, Política y Valores*, 13(3).
- Román, G. (2024). El rol de la IA en la enseñanza de matemáticas en entornos virtuales. *Reincisol*, 3(6), 2111-2133. [https://doi.org/10.59282/reincisol.V3\(6\)2111-2133](https://doi.org/10.59282/reincisol.V3(6)2111-2133)
- Villena, C., Calsin, W., Espinoza, D., & Rengifo, J. (2024). Aplicación de la inteligencia artificial en la resolución de problemas matemáticos en el nivel universitario. *Revista Social Fronteriza*, 4(5).
- Zamora, M., Bernal, A., Ruiz, O., Cholango, E., & Santana, A. (2024). Impulsando el aprendizaje en el aula: El rol de las aplicaciones de aprendizaje adaptativo impulsadas por inteligencia artificial en la educación básica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(3), 4301-4318. https://doi.org/10.37811/cl_rcm.v8i3.11645
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education: Where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>

APLICACIÓN DEL CÁLCULO DIFERENCIAL EN LAS DIFERENTES ÁREAS DE LA INGENIERÍA

Leyva Romero, Melva Jamie;

PT / Instituto Tecnológico de Boca del Río
melvaleyva@bdelrio.tecnm.mx

Vichy Cruz, Aned María;

PA / Instituto Tecnológico de Boca del Río
anedvichy@bdelrio.tecnm.mx

Herrera Triana, Jesús;

PTC/ Instituto Tecnológico de Boca del Río
jesusherrera@bdelrio.tecnm.mx

Rodríguez Moreno, Celia Isabel;

PT/ Instituto Tecnológico de Boca del Río
celiarodriguez@bdelrio.tecnm.mx

INTRODUCCIÓN

La transformación digital ha redefinido los procesos educativos en la educación superior, impulsando la incorporación de tecnologías emergentes que fortalecen la enseñanza, el aprendizaje y el desarrollo de competencias profesionales. En este escenario, la Inteligencia Artificial (IA) se ha consolidado como una de las tecnologías con mayor potencial para transformar los ambientes de aprendizaje, debido a su capacidad para personalizar la enseñanza, proporcionar retroalimentación inmediata, analizar el progreso académico y adaptar los contenidos a las necesidades individuales de los estudiantes. Estas características favorecen un aprendizaje más activo, autónomo y centrado en el estudiante, al tiempo que apoyan la labor docente mediante herramientas inteligentes para la planificación, evaluación y seguimiento del proceso educativo.

En las ciencias básicas, y particularmente en la enseñanza del cálculo diferencial, la incorporación de recursos digitales e inteligencia artificial representa una alternativa para enfrentar las dificultades que tradicionalmente presenta esta asignatura. El cálculo diferencial constituye uno de los pilares de la formación en ingeniería, ya que proporciona los fundamentos matemáticos necesarios para el análisis del cambio, la optimización de procesos, la modelación de sistemas y la resolución de problemas propios de las diferentes disciplinas de la ingeniería. Sin embargo, diversos estudios coinciden en que esta materia registra elevados índices de reprobación y abandono debido a la complejidad conceptual, el alto nivel de abstracción y la dificultad para relacionar los contenidos teóricos con situaciones reales de aplicación profesional.

La evolución reciente de la Inteligencia Artificial ha permitido el desarrollo de asistentes virtuales, sistemas de tutoría inteligente, plataformas adaptativas, simuladores interactivos y modelos generativos que ofrecen nuevas oportunidades para mejorar la comprensión de conceptos matemáticos complejos. Estas herramientas favorecen la visualización de funciones, el análisis paso a paso de procedimientos, la generación de ejercicios personalizados y la retroalimentación inmediata, promoviendo procesos de aprendizaje más significativos y el fortalecimiento del razonamiento matemático. No obstante, su implementación debe realizarse bajo un enfoque pedagógico que privilegie el pensamiento crítico, la resolución de problemas y la participación activa del estudiante, evitando que la IA sustituya el proceso de construcción del conocimiento.

En el contexto de la educación en ingeniería, la integración de la Inteligencia Artificial responde a las demandas de la transformación digital y de la Industria 4.0, las cuales requieren profesionistas capaces de combinar conocimientos científicos, competencias digitales y habilidades para el aprendizaje permanente. En consecuencia, la incorporación de herramientas inteligentes en la enseñanza del cálculo diferencial no solo contribuye a mejorar el rendimiento académico, sino que también fortalece competencias transversales como el pensamiento analítico, la toma de decisiones, la resolución de problemas complejos y el uso ético de las tecnologías digitales.

Con base en este contexto, el presente estudio tiene como propósito analizar la Inteligencia Artificial como herramienta de aprendizaje en las ciencias básicas, específicamente en la enseñanza del cálculo diferencial, identificando sus aportaciones al desarrollo de competencias matemáticas y profesionales en estudiantes de ingeniería, así como las oportunidades y desafíos que representa su incorporación en los procesos de enseñanza y aprendizaje.

PROBLEMATICA

Diversas investigaciones desarrolladas en el ámbito de la educación superior evidencian que un porcentaje significativo de estudiantes presenta dificultades para comprender los conceptos fundamentales del cálculo diferencial y, especialmente, para transferir dichos conocimientos a la resolución de problemas propios

de su campo profesional. Esta situación representa uno de los principales desafíos en la formación de ingenieros, debido a que limita el desarrollo del razonamiento matemático, la capacidad de análisis y la aplicación de modelos para la solución de problemas reales.

Entre los factores que contribuyen a esta problemática se identifican las deficiencias en los conocimientos matemáticos adquiridos durante los niveles educativos previos, las cuales dificultan la comprensión de conceptos como límites, continuidad, derivadas y sus aplicaciones. Así mismo, persiste el predominio de metodologías de enseñanza tradicionales centradas en la transmisión de contenidos y la memorización de procedimientos algorítmicos, lo que restringe la construcción de aprendizajes significativos y el desarrollo del pensamiento crítico.

Otro elemento relevante es la limitada articulación entre los contenidos teóricos del cálculo diferencial y los contextos de aplicación propios de las diferentes áreas de la ingeniería. Esta desvinculación dificulta que los estudiantes reconozcan la utilidad de los conceptos matemáticos para modelar, analizar y optimizar procesos, reduciendo su motivación e interés por la asignatura. De igual manera, el uso insuficiente de tecnologías digitales y herramientas basadas en Inteligencia Artificial limita el acceso a estrategias de aprendizaje adaptativo, recursos interactivos y sistemas de retroalimentación inmediata que favorecen el aprendizaje autónomo y la autorregulación del conocimiento.

En conjunto, estas condiciones repercuten negativamente en el rendimiento académico, incrementan los niveles de desmotivación y ansiedad hacia las matemáticas, y contribuyen a los elevados índices de reprobación y abandono escolar registrados en las asignaturas de ciencias básicas. En este contexto, resulta pertinente explorar estrategias didácticas apoyadas en Inteligencia Artificial que promuevan un aprendizaje más dinámico, contextualizado y orientado al desarrollo de competencias matemáticas aplicables a la formación profesional en ingeniería.

JUSTIFICACIÓN

La incorporación de la Inteligencia Artificial (IA) en los procesos de enseñanza y aprendizaje constituye una estrategia innovadora con un alto potencial para fortalecer la formación en ciencias básicas, particularmente en el área del cálculo diferencial. El desarrollo de herramientas inteligentes, como sistemas de tutoría adaptativa, asistentes virtuales, plataformas de aprendizaje personalizadas y modelos generativos, permite diversificar las estrategias didácticas y responder a las necesidades individuales de los estudiantes, favoreciendo un aprendizaje más significativo, autónomo y centrado en el desarrollo de competencias.

Desde una perspectiva pedagógica, la IA facilita la personalización de los procesos formativos mediante la generación de explicaciones ajustadas al nivel de conocimiento del estudiante, la creación de ejercicios con diferentes grados de complejidad, la retroalimentación inmediata y el seguimiento continuo del progreso académico. Asimismo, el empleo de recursos interactivos para la representación gráfica y la simulación de fenómenos matemáticos contribuye a reducir el nivel de abstracción característico del cálculo diferencial, favoreciendo la comprensión conceptual y el fortalecimiento del razonamiento matemático.

Por otra parte, la contextualización del cálculo diferencial en la resolución de problemas reales de ingeniería promueve la integración de los conocimientos teóricos con su aplicación práctica en escenarios profesionales. Este enfoque favorece el desarrollo del pensamiento crítico, la capacidad de análisis, la modelación matemática, la resolución de problemas complejos y la toma de decisiones fundamentadas en evidencia, competencias consideradas esenciales para la formación de ingenieros en el contexto de la transformación digital y la Industria 4.0.

En este sentido, la presente investigación se justifica por la necesidad de generar evidencia sobre las contribuciones de la Inteligencia Artificial como herramienta de apoyo al aprendizaje del cálculo diferencial, así como por su potencial para mejorar el rendimiento académico, fortalecer las competencias matemáticas y digitales, e impulsar la innovación en los procesos de enseñanza y aprendizaje de las ciencias básicas en la educación superior.

OBJETIVOS

Objetivo general

Analizar el potencial de la Inteligencia Artificial como herramienta de apoyo al aprendizaje para fortalecer la enseñanza del cálculo diferencial y favorecer su aplicación en la resolución de problemas en las diferentes áreas de la ingeniería.

Objetivos específicos

- Identificar las principales aplicaciones de la Inteligencia Artificial en los procesos de enseñanza y aprendizaje de las ciencias básicas en la educación superior.
- Analizar la importancia del cálculo diferencial como fundamento matemático para el desarrollo de competencias analíticas y la resolución de problemas en la formación de ingenieros.
- Describir las principales aplicaciones del cálculo diferencial en las diferentes disciplinas de la ingeniería, destacando su contribución a la modelación, optimización y análisis de procesos.
- Proponer estrategias didácticas sustentadas en herramientas de Inteligencia Artificial que favorezcan el aprendizaje significativo, el pensamiento crítico y el desarrollo de competencias matemáticas y digitales en estudiantes de ingeniería.

METODO

La presente investigación se desarrolló bajo un enfoque cualitativo, con un diseño de investigación documental, orientado al análisis y la sistematización del conocimiento científico relacionado con la aplicación de la Inteligencia Artificial (IA) en los procesos de enseñanza y aprendizaje del cálculo diferencial en la educación superior. Este enfoque permitió identificar, comparar e interpretar las principales aportaciones teóricas y empíricas reportadas en la literatura especializada, con el propósito de comprender el potencial de la IA como recurso para fortalecer la formación en ciencias básicas en los programas de ingeniería.

La recopilación de información se realizó mediante una revisión bibliográfica sistemática de artículos científicos, libros especializados, memorias de congresos y documentos publicados por organismos internacionales vinculados con la innovación educativa y la transformación digital. Para garantizar la actualidad y pertinencia de la información, se seleccionaron publicaciones editadas entre los años 2020 y 2026.

La búsqueda de literatura científica se efectuó en bases de datos de reconocido prestigio académico, entre ellas Scopus, Web of Science, IEEE Xplore, ScienceDirect y Google Académico.

Como criterios de inclusión se consideraron investigaciones publicadas en revistas arbitradas, capítulos de libros, documentos institucionales y estudios relacionados con la aplicación de la Inteligencia Artificial en la educación superior, la enseñanza de las matemáticas y la formación en ingeniería. Se excluyeron publicaciones duplicadas, documentos sin revisión por pares y estudios cuyo contenido no guardaba relación con los objetivos de la investigación.

Posteriormente, la información recuperada fue organizada, clasificada y analizada mediante un proceso de análisis de contenido, identificando categorías temáticas relacionadas con las aplicaciones educativas de la Inteligencia Artificial, las dificultades en el aprendizaje del cálculo diferencial, las estrategias didácticas apoyadas en tecnologías inteligentes y las aplicaciones del cálculo diferencial en las distintas áreas de la ingeniería. Este procedimiento permitió integrar y sintetizar la evidencia científica disponible, proporcionando una base teórica sólida para el desarrollo del estudio.

MARCO TEORICO

Inteligencia Artificial en la educación

La Inteligencia Artificial (IA) se define como un campo interdisciplinario de la informática orientado al desarrollo de sistemas capaces de ejecutar tareas que tradicionalmente requieren capacidades cognitivas humanas, tales como el aprendizaje, el razonamiento, la resolución de problemas, el reconocimiento de patrones y la toma de decisiones. En el ámbito educativo, la IA ha emergido como una tecnología con alto potencial para transformar los procesos de enseñanza y aprendizaje mediante el diseño de experiencias personalizadas, adaptativas e interactivas que favorecen el desarrollo de competencias disciplinares y digitales.

En la educación superior, las aplicaciones de la IA incluyen sistemas de tutoría inteligente, asistentes virtuales, plataformas de aprendizaje adaptativo, analítica del aprendizaje y herramientas de evaluación automatizada que permiten ofrecer retroalimentación inmediata y monitorear el progreso académico de los estudiantes. Asimismo, el desarrollo de modelos de inteligencia artificial generativa ha ampliado las posibilidades para la explicación de conceptos complejos, la generación de ejercicios personalizados, la resolución guiada de problemas y el fortalecimiento del aprendizaje autónomo.

Entre las herramientas de mayor difusión se encuentran ChatGPT, Microsoft Copilot, Google Gemini y Wolfram Alpha, las cuales facilitan el análisis de procedimientos matemáticos, la interpretación de resultados, la visualización de funciones y la explicación paso a paso de problemas relacionados con el cálculo diferencial. No obstante, la literatura especializada coincide en que estas tecnologías deben integrarse dentro de estrategias pedagógicas que promuevan el pensamiento crítico, la reflexión y la construcción activa del conocimiento, evitando que el estudiante adopte una actitud pasiva frente al aprendizaje.

EL CÁLCULO DIFERENCIAL COMO FUNDAMENTO DE LAS CIENCIAS BÁSICAS

El cálculo diferencial constituye uno de los pilares fundamentales de la formación científica y tecnológica de los futuros ingenieros. Su objeto de estudio comprende el análisis de las tasas de cambio y el comportamiento local de las funciones mediante el concepto de derivada, proporcionando herramientas matemáticas indispensables para modelar, interpretar y optimizar fenómenos presentes en las ciencias naturales, la economía, la industria y la tecnología.

Los conceptos de límite, continuidad, derivada, reglas de derivación, razones de cambio, Máximos y mínimos, así como los problemas de optimización, constituyen la base conceptual sobre la cual se desarrollan modelos matemáticos capaces de describir sistemas dinámicos y apoyar la toma de decisiones en diferentes contextos profesionales. En consecuencia, el dominio del cálculo diferencial favorece el desarrollo del razonamiento lógico, la abstracción, el pensamiento analítico y la capacidad para resolver problemas complejos, competencias esenciales en la formación integral del ingeniero.

Aplicaciones del cálculo diferencial en las diferentes áreas de la ingeniería

El carácter transversal del cálculo diferencial permite su aplicación en prácticamente todas las disciplinas de la ingeniería. En Ingeniería Industrial, las derivadas se emplean para optimizar procesos productivos,

minimizar costos de operación, maximizar utilidades y diseñar estrategias orientadas al mejoramiento continuo y al control de calidad.

En Ingeniería Mecánica, el cálculo diferencial constituye una herramienta indispensable para el análisis del movimiento de mecanismos, la determinación de velocidades y aceleraciones, así como para el diseño y evaluación del comportamiento de componentes mecánicos sometidos a diferentes condiciones de operación.

En Ingeniería Civil, las derivadas son utilizadas para el diseño geométrico de carreteras, el análisis de pendientes, el estudio de deformaciones estructurales y la modelación del comportamiento de materiales sometidos a cargas estáticas y dinámicas.

Por su parte, en Ingeniería Electrónica, el cálculo diferencial permite analizar el comportamiento de señales eléctricas variables en el tiempo, estudiar circuitos electrónicos, diseñar sistemas de control y modelar procesos dinámicos presentes en sistemas automatizados.

En Ingeniería en Gestión Empresarial, las herramientas del cálculo diferencial son ampliamente utilizadas para la optimización de recursos, la formulación de modelos económicos, el análisis marginal, la determinación de niveles óptimos de producción y el pronóstico de la demanda, facilitando la toma de decisiones basada en modelos cuantitativos.

Inteligencia Artificial y aprendizaje significativo

Desde la perspectiva de la teoría del aprendizaje significativo propuesta por Ausubel, el aprendizaje ocurre cuando la nueva información logra relacionarse de manera sustantiva y no arbitraria con los conocimientos previos del estudiante. Bajo este enfoque, la Inteligencia Artificial puede constituirse en un recurso didáctico que favorece la construcción del conocimiento mediante actividades contextualizadas, simulaciones, representaciones gráficas, ejercicios adaptativos y procesos de retroalimentación inmediata. La interacción con sistemas inteligentes permite identificar errores conceptuales, ofrecer explicaciones personalizadas y adaptar la complejidad de las actividades al ritmo de aprendizaje de cada estudiante, favoreciendo procesos de autorregulación y aprendizaje autónomo. En consecuencia, la IA fortalece la comprensión conceptual del cálculo diferencial al reducir el nivel de abstracción de los contenidos y facilitar su vinculación con problemas reales de la ingeniería.

DESARROLLO

La integración de herramientas de Inteligencia Artificial en la enseñanza del cálculo diferencial representa una transformación significativa de los modelos tradicionales de enseñanza. En este nuevo escenario, el docente asume el papel de mediador pedagógico, diseñador de experiencias de aprendizaje y facilitador del desarrollo de competencias, mientras que el estudiante adopta un rol activo en la construcción del conocimiento mediante la exploración, el análisis y la resolución de problemas contextualizados.

Durante el aprendizaje de temas relacionados con la optimización, por ejemplo, las herramientas de IA permiten que los estudiantes verifiquen procedimientos, identifiquen errores de razonamiento, comparen diferentes estrategias de solución e interpreten los resultados obtenidos desde una perspectiva matemática y profesional. Esta interacción favorece el desarrollo del pensamiento crítico y promueve una comprensión más profunda de los conceptos involucrados.

La aplicación del cálculo diferencial adquiere especial relevancia cuando los problemas matemáticos se contextualizan en escenarios propios de las distintas áreas de la ingeniería. En Ingeniería en Gestión Empresarial, las derivadas permiten determinar niveles óptimos de producción, maximizar utilidades y minimizar costos mediante modelos matemáticos que pueden ser analizados y visualizados con apoyo de herramientas de Inteligencia Artificial. De manera similar, en Ingeniería Civil, estas herramientas facilitan

el análisis de pendientes, deformaciones estructurales y diseños geométricos; en Ingeniería Mecánica apoyan el estudio del movimiento, la velocidad y la aceleración de mecanismos; mientras que en Ingeniería Electrónica contribuyen al análisis de señales, circuitos y sistemas dinámicos.

A pesar de las ventajas que ofrece la Inteligencia Artificial, su incorporación en los procesos educativos no implica la sustitución de la función docente. Por el contrario, su valor radica en complementar las estrategias didácticas mediante recursos que favorecen el aprendizaje autónomo, la atención personalizada y el desarrollo de competencias digitales. En este sentido, el aprovechamiento pedagógico de la IA requiere promover el uso ético y responsable de estas tecnologías, fortaleciendo simultáneamente el pensamiento crítico, la argumentación científica, la capacidad de análisis y la integridad académica, con el propósito de evitar una dependencia excesiva de las respuestas generadas por sistemas inteligentes y garantizar una formación profesional sólida e integral.

CONCLUSIONES

La presente investigación permitió identificar que la Inteligencia Artificial constituye una herramienta con un elevado potencial para fortalecer los procesos de enseñanza y aprendizaje del cálculo diferencial en la educación superior. La evidencia analizada muestra que la incorporación de tecnologías inteligentes favorece la comprensión de conceptos matemáticos complejos mediante estrategias de aprendizaje personalizadas, recursos interactivos y mecanismos de retroalimentación inmediata, contribuyendo al desarrollo de un aprendizaje más significativo y centrado en el estudiante.

Asimismo, la integración de herramientas basadas en Inteligencia Artificial facilita la vinculación entre los fundamentos teóricos del cálculo diferencial y su aplicación en la resolución de problemas propios de las diferentes áreas de la ingeniería. Esta articulación promueve el desarrollo de competencias matemáticas, analíticas, digitales y profesionales indispensables para enfrentar los desafíos de la transformación digital, la Industria 4.0 y los nuevos escenarios de innovación tecnológica.

Los resultados de la revisión documental también evidencian que el aprovechamiento pedagógico de la Inteligencia Artificial puede contribuir al incremento de la motivación estudiantil, al fortalecimiento del aprendizaje autónomo y al desarrollo del pensamiento crítico, siempre que su implementación se encuentre respaldada por estrategias didácticas orientadas al logro de aprendizajes significativos y al uso reflexivo de estas tecnologías.

No obstante, la incorporación de la Inteligencia Artificial en la enseñanza del cálculo diferencial plantea importantes desafíos relacionados con la formación y actualización permanente del profesorado, el diseño de metodologías activas, la disponibilidad de infraestructura tecnológica y la promoción de principios éticos en el uso de sistemas inteligentes. En este sentido, la IA debe concebirse como un recurso complementario que potencia la labor docente, sin sustituir el papel del profesor como mediador del aprendizaje y promotor del razonamiento matemático y la construcción del conocimiento.

Finalmente, se concluye que la integración estratégica de herramientas de Inteligencia Artificial en la enseñanza del cálculo diferencial representa una oportunidad para innovar los procesos educativos en las ciencias básicas, mejorar el desempeño académico de los estudiantes de ingeniería y favorecer el desarrollo de competencias acordes con las demandas de la educación superior y del entorno profesional contemporáneo. Se recomienda que futuras investigaciones evalúen, mediante estudios empíricos, el impacto de estas herramientas en el rendimiento académico, la resolución de problemas y el desarrollo de competencias matemáticas en distintos contextos educativos.

REFERENCIAS

- Alcántara, W. M., Pérez González, O. L., & Bueno García, S. (2024). Estrategia didáctica con el uso de la inteligencia artificial para el Cálculo Diferencial en Ingeniería. *Educación Matemática Debate*, 8. <https://doi.org/10.46551/emd.v8n14a04>
- Kamalov, F., Santandreu Calonge, D., & Gurrib, I. (2023). New Era of Artificial Intelligence in Education: Towards a Sustainable Multifaceted Revolution. *arXiv*.
- Mora Casasola, M. F. (2023). Implementing Digital Educational Resources: A Systematic Review From a Differential Calculus Teaching Perspective. *Revista Digital: Matemática, Educación e Internet*, 24(1). <https://doi.org/10.18845/rdmei.v24i1.6709>
- Silva, D. G. C., Veloso Garcia, R., Romão, E. C., & Zapata Zapata, J. F. (2024). Teaching methodologies in calculus for engineering: A quantitative analysis. *Caderno Pedagógico*.
- Chan, C. K. Y., & Tsi, L. H. Y. (2023). The AI Revolution in Education: Will AI Replace or Assist Teachers in Higher Education? *arXiv*.
- Ausubel, D. P. (2002). *Adquisición y retención del conocimiento: Una perspectiva cognitiva*. Paidós.
- OpenAI. (2025). ChatGPT para educación. <https://openai.com>
- Stewart, J. (2021). *Cálculo de una variable: Trascendentes tempranas* (9.ª ed.). Cengage Learning.
- Thomas, G. B., Weir, M. D., & Hass, J. (2022). *Cálculo* (15.ª ed.). Pearson.
- UNESCO. (2023). Orientaciones sobre la inteligencia artificial generativa en la educación y la investigación. UNESCO. <https://unesdoc.unesco.org/>
- Zill, D. G. (2020). *Cálculo con geometría analítica*. McGraw-Hill.

DEL RESULTADO DIRECTO AL ANDAMIAJE COGNITIVO: USO DE LLMS COMO TUTORES SOCRÁTICOS EN LA RESOLUCIÓN DE PROBLEMAS DE CIENCIAS BÁSICAS

Lara Colón, Ricardo;
PA TecNM/Instituto Tecnológico de Pabellón de Arteaga
ricardo.lc@pabellon.tecnm.mx

Romo Rodríguez, Pamela;
PA TecNM/Instituto Tecnológico de Pabellón de Arteaga
pamela.rr@pabellon.tecnm.mx

Arceo Luna, Ana Rosa;
PI/ Universidad Pedagógica Nacional, 011 Aguascalientes
ana.arceo@upn011.edu.mx

INTRODUCCIÓN

La llegada de los Grandes Modelos de Lenguaje (LLMs) a las aulas de ciencias básicas en las universidades ha generado un efecto que varios autores describen con preocupación: el riesgo de que los estudiantes deleguen al modelo el trabajo cognitivo que previamente realizaban ellos mismos, comprometiendo el desarrollo de pensamiento crítico (Larson et al., 2024; Lee & Low, 2024). Este cambio, aparentemente inofensivo en cuanto a eficiencia inmediata, oculta lo que este artículo propone llamar “atrofia por sustitución”: una pérdida progresiva de habilidades de razonamiento abstracto cuando el aprendiz actúa como consultor del resultado más que como su constructor. Cuando el modelo entrega la solución final sin mediación, el aprendiz es excluido del viaje epistémico que constituye, en estricto sentido, el aprendizaje de la ciencia: formular hipótesis, contrastarlas, reformular. No sólo se pierde la respuesta correcta si ésta se obtiene sin esfuerzo sino que se pierde el desarrollo del razonamiento y la construcción de la arquitectura mental que sustenta el saber.

Más allá de lo tecnológico, el dilema es epistemológico. Sabemos que el espacio en que se produce el aprendizaje está entre lo que puede hacer por sí mismo y lo que hace con apoyo de alguien más capaz (Vygotsky, 1978). Esta zona de desarrollo próximo, requiere de un andamiaje que deberá ser disminuido gradualmente: el mediador interviene cuando la tarea excede la competencia autónoma y se retira cuando ésta se consolida. La configuración por defecto de los LLMs, viola este principio. No proveen un andamiaje, sino que sustituyen todo el proceso. El estudiante recibe el producto, sin participar en su elaboración. En términos de Wood, Bruner y Ross, equivale a dejar el andamio fijo indefinidamente y a sustituir el papel del aprendiz en la estructura, creando una paradoja: más asistencia, menos aprendizaje. La literatura empírica reciente sobre sistemas inteligentes de tutoría (ITS) en contextos educativos reales confirma que el valor pedagógico depende menos de la potencia del sistema que de la profundidad instruccional con se integra en la práctica (Wang et al., 2023).

PROBLEMÁTICA

En este escenario la problemática es doble. Por un lado tenemos que el uso pasivo de los LLMs como un oráculo, reduce la capacidad de razonamiento abstracto del estudiante, un fenómeno que este artículo propone conceptualizar como “atrofia por sustitución”, en línea con advertencias generales en la literatura reciente que respecto al pensamiento crítico en la era de la IA generativa (Larson et al., 2024; Lee & Low, 2024). Por otro lado, los errores conceptuales persistentes en ciencias básicas —la confusión entre masa y peso, la interpretación estática del equilibrio químico, la suposición de que toda fuerza produce movimiento— son estructuras cognitivas estabilizadas de ideas erróneas que sobreviven a la instrucción formal, lo que ha sido documentado por revisiones sistemáticas de ideas erróneas en ciencias naturales y química (Guerra-Reyes et al., 2024; Suparman et al., 2024). La pregunta central que guía este trabajo es: ¿Es suficiente con prohibir las respuestas directas para que los LLMs funcionen como un andamio cognitivo, o se requiere una arquitectura de prompt más compleja que regule también la cadencia, la profundidad de sondeo y la gestión afectiva del error?

JUSTIFICACIÓN

Tres razones justifican esta investigación. La primera, es la urgencia pedagógica: el uso masivo de los LLMs en aulas STEM nos obliga a pensar detenidamente en su rol antes de que se consoliden prácticas sustitutivas que sean difíciles de revertir. La segunda, el vacío metodológico: la literatura especializada registra avances en el uso de ChatGPT como contraparte socrática que ayude a afianzar habilidades

dialógicas en docentes (Gregorcic et al., 2024) y en el tratamiento de ideas erróneas mediante el uso de IA generativa (El Fathi et al., 2025), sin embargo hay una falta de formalización del prompt restrictivo como un diseño estandarizado y estructurado, de forma que cualquier docente o investigador pueda adaptar y aplicar directamente en distintos contextos obteniendo el resultado pedagógico esperado. La tercera, el potencial epistémico: el reconfigurar el papel del LLM de oráculo a andamiaje cognitivo nos abre un camino inédito para que la inteligencia artificial contribuya, no a automatizar el aprendizaje, sino a su profundización. La hipótesis de trabajo sostiene que eliminar la respuesta directa es condición necesaria pero no suficiente; un efectivo andamiaje demanda una parametrización multidimensional del prompt, articulada con una taxonomía explícita de intervenciones y con un diseño para la captura de evidencia.

OBJETIVO

El objetivo general de este artículo es proponer, formalizar y discutir un marco metodológico para el uso de LLMs como tutores socráticos en problemas de ciencias básicas, específicamente en física básica y química cuantitativa. De este objetivo general, se derivan los siguientes objetivos específicos: (a) detallar la parametrización del prompt de restricción, incluyendo el bloqueo de respuestas directas y la guía basada en preguntas; (b) diseñar una taxonomía operacional de intervenciones tutorales; (c) examinar el impacto diferencial de la tutoría socrática en errores conceptuales y en la regulación afectiva de la frustración; y (d) reflexionar críticamente en la escalabilidad y las limitaciones institucionales de estas herramientas.

MÉTODO

El estudio adopta un enfoque cualitativo-teórico para el diseño instruccional, complementado por una revisión sistemática de la literatura reciente (2023-2025) en tutoría socrática con LLMs, sistemas de tutoría inteligente, y el tratamiento de ideas erróneas en STEM. Las fuentes consultadas incluyen índices científicos reconocidos. El proceso de análisis está dividido en tres fases: (i) síntesis de marcos de trabajo teóricos relevantes —Zona de Desarrollo Próximo, dificultad deseable, dinámicas afectivas, auto-explicación; (ii) formalización de la arquitectura del prompt restrictivo y su taxonomía de intervenciones; (iii) discusión del impacto esperado en las ideas erróneas y el manejo afectivo. La población objetivo para la intervención propuesta consiste en estudiantes de ingeniería de primer año inscritos en cursos física básica y química cuantitativa. Las edades de los estudiantes están entre 18 y 19 años, siendo el 36% mujeres.

MARCO TEÓRICO

La reconfiguración del LLM de oráculo a andamiaje cognitivo está anclada en un marco de trabajo teórico que integra tres tradiciones: el constructivismo sociocultural Vygotskiano, la teoría del andamiaje de Wood, Bruner y Ross, y la tradición socrática del interrogatorio mayéutico sistematizado por Collins y Stevens. Estos tres pilares convergen en una percepción común: el aprendizaje profundo ocurre cuando el aprendiz es guiado, no cuando es reemplazado. La zona de desarrollo próximo define el rango donde la mediación es productiva; el andamiaje prescribe la modalidad de la mediación; y la tutoría socrática establece la pregunta abierta como la unidad mínima de interacción pedagógica. Al conjugarse lo anterior el aprendiz alcanza la zona de desarrollo potencial.

La literatura reciente documenta avances significativos en la operacionalización de estos principios usando LLMs. Gregorcic et al. (2024) han mostrado, en un estudio de prueba de concepto, que ChatGPT puede ser usado como contraparte con la cual los maestros de física pueden practicar sus habilidades de diálogo socrático antes de llevarlas al aula presencial. El Fathi et al. (2025), por su parte, han documentado cómo al integrar ChatGPT en un marco de trabajo instruccional constructivista mejora el entendimiento conceptual en STEM y ayuda a direccionar las ideas erróneas en termodinámica. Fakour e Imani (2025), en un estudio con 230 estudiantes universitarios, compararon percepciones sobre tutores humanos y de ChatGPT como agentes socráticos tutorando el pensamiento crítico. Estos estudios convergen en una observación clave: el valor pedagógico de los LLMs no está en su habilidad para responder, sino en su habilidad de formular preguntas.

ARQUITECTURA DEL PROMPT DE RESTRICCIÓN

El diseño del tutor socrático está basado en una premisa contraintuitiva: el LLM debe saber más de lo que revela, y debe ser capaz de resolver el problema sin verbalizar nunca la solución. Esto requiere un prompt de sistema que opera como una caja negra instruccional, donde la competencia del modelo está deliberadamente restringida mediante reglas de interacción. El núcleo de esta arquitectura está resumido en cinco reglas instruccionales no negociables: (1) Rol: el modelo actúa como un experto socrático cuya meta no es resolver el problema sino guiar al estudiante a resolverlo por sí mismo; (2) Prohibición central: bajo ninguna circunstancia el modelo debe proporcionar la respuesta final, el resultado numérico, o la expresión algebraica cerrada; (3) Forma: cada intervención debe finalizar con una pregunta, con un tamaño máximo de 60 palabras; (4) Profundidad: proceder mediante pruebas incrementales – clarificación de suposiciones, exploración de variables, contrastación con casos límite, construcción paso a paso –; (5) Tono: cordial, mesurado, sin adulación, reconociendo respuestas correctas y señalando errores sin juzgar.

Estas cinco guías no operan de manera aislada. Constituyen un sistema interconectado en que la prohibición central solo adquiere un significado pedagógico cuando se asegura un ritmo interrogativo, y en el fondo se evita una conversación que redunde en interrogación superficial. Por su parte, el tono regula la dimensión afectiva: la frustración de un estudiante frente a la negativa sostenida del modelo puede convertirse rápidamente en desconexión cognitiva. La dinámica afectiva que sitúa al aprendizaje profundo en la zona entre la confusión productiva y la frustración abrumadora fue modelada por D'Mello et al. (2014) y constituye una coordenada central en el diseño de sistemas tutorales inteligentes recientes (Létourneau et al., 2025; Son, 2024).

TAXONOMÍA DE INTERVENCIONES

A partir del prompt central, se diseñó una taxonomía de cuatro movimientos tutorales, cada uno asociado con un momento específico en el ciclo de resolución. La taxonomía no es exhaustiva, es operativa. Su función es guiar la generación del modelo y, simultáneamente proporcionar un marco de trabajo analítico para evaluar el rastro interaccional. Los movimientos son los siguientes:

(1) Clarificación: cuestiona las suposiciones implícitas en el enunciado. Ejemplo: “¿Que significa ‘equilibrio’ aquí?”; “¿Lo estas usando en un sentido estático o dinámico?” (2) Sondeo: explora el razonamiento que puentes la brecha entre los datos y la conclusión. Ejemplo: “Llegaste a $v=12$ m/s. ¿Qué principio usaste para relacionar aceleración y tiempo?” (3) Contraejemplo: introduce un caso límite que reta la respuesta del estudiante. Ejemplo: “Si tu razonamiento fuera correcto, ¿qué pasaría si la masa fuera el doble?” (4) Refutación suave: señala la inconsistencia sin penalizar al estudiante. Ejemplo: “Dices que la fuerza neta es cero, pero también que el cuerpo está acelerando. ¿Cómo pueden estas dos afirmaciones coexistir?” Esta secuencia replica artificialmente la trayectoria que Chi et al. identificaron como el motor de la autoexplicación efectiva (Chi et al., 1994), un principio que han adoptado diseños recientes de

retroalimentación y andamiaje tecnológico en ciencias para promover el entendimiento profundo (Kaldaras et al., 2024). La diferencia respecto a un tutor humano es la escala y la disponibilidad, no en la estructura dialógica. La diferencia comparada con un LLMs no restringido es decisiva: sin la taxonomía, el modelo deriva hacia la explicación magistral; con ella, se ve obligado a sostener la interacción con el estudiante.

DISEÑO DE LA INTERVENCIÓN PEDAGÓGICA

La intervención fue diseñada para una población de estudiantes de primer año de ingeniería en cursos de física básica (cinemática, dinámica newtoniana) y química cuantitativa (estequiometría, equilibrio químico). El dominio se eligió por dos razones convergentes: la densidad de ideas erróneas persistentes documentadas en la literatura (Guerra-Reyes et al., 2024; Suparman et al., 2024) y la posibilidad de diseñar problemas con soluciones numéricas verificables, un requerimiento metodológico esencial para comparar enfoques instruccionales. El ciclo de interacción consiste de cuatro fases: (i) diagnóstico inicial con un problema cognitivamente demandante; (ii) interacción tutor-estudiante de entre 8 y 12 turnos; (iii) problema isomorfo de transferencia inmediata; (iv) problema de transferencia lejana a las 72 horas. La captura de evidencias se diseñó en tres capas: registro completo de turnos, etiquetado automático de intervenciones según la taxonomía, y registro de marcadores afectivos léxicos (latencia, vacilación, reformulación) asociados a la frustración. Esta arquitectura de trazas se inspira en los enfoques de learning analytics que Drugova et al. (2024) sistematizan para educación superior, pero los reorienta hacia un objetivo distinto: no predecir el rendimiento, sino documentar el desplazamiento cognitivo que ocurre, o no ocurre, durante la interacción socrática. El cuadro siguiente sintetiza el contraste entre ambas modalidades:

Dimensión	Modalidad pasiva	Modalidad socrática
Rol del LLM	Oráculo	Mediador
Resultado al estudiante	Solución completa	Ausencia deliberada
Unidad interaccional	Afirmación	Pregunta
Carga cognitiva	Extrínseca, baja	Intrínseca, calibrada
Riesgo dominante	Atrofia del razonamiento	Fatiga interaccional
Transferencia esperada	Reducida	Amplia

CONCLUSIONES

La reconfiguración del LLM de oráculo a andamio cognitivo no es un ajuste técnico. Es un desplazamiento epistemológico. Exige renunciar a la idea de que la respuesta correcta, suministrada en tiempo real, equivale al aprendizaje, y aceptar que la mediación socrática, con su cadencia interrogativa y su negativa deliberada, posibilita la trayectoria de aprendizaje como sujeto cognoscente. El prompt restrictivo no neutraliza la capacidad del modelo; la disciplina. La poda, en este caso, es pedagógica.

Los hallazgos esperados, a la luz del marco teórico articulado, apuntan a una reducción significativa de la persistencia de errores conceptuales bajo la modalidad socrática, en contraste con la modalidad pasiva. Esta expectativa se sostiene en el principio de auto explicación formulado por Chi et al. (1994): al no recibir la respuesta correcta, el estudiante se ve obligado a verbalizar su razonamiento, exponiendo la idea errónea a la tensión del contraejemplo y a la refutación suave. La gestión afectiva de la frustración, regulada en el presente diseño por el reconocimiento del avance parcial y la modulación del ritmo —mecanismos que se proponen aquí como extensión del marco— busca mantener al estudiante en la franja óptima entre confusión productiva y colapso afectivo, donde D'Mello et al. (2014) ubican el aprendizaje profundo. La evidencia empírica de Faber et al. (2024) sobre el andamiaje adaptativo confirma que la regulación a la medida reduce la carga cognitiva sin sacrificar la dificultad intrínseca, principio consistente con el rol aquí asignado al tutor socrático. No obstante, emergen tensiones no triviales: la fatiga interaccional tras cadenas interrogativas prolongadas y el riesgo —no cubierto por las auditorías empíricas disponibles, pero señalado como preocupación abierta por la literatura— de que el LLM, sin compromiso epistémico con la disciplina, conduzca al estudiante por trayectorias conceptuales equivocadas sin que la inconsistencia se haga visible.

Las limitaciones de la propuesta son, sin embargo, sustantivas. La calidad del andamiaje depende críticamente de la ingeniería del prompt, una práctica aún más artesanal que sistemática, sensible a la versión del modelo, al dominio y al estilo del estudiante. La calibración del ritmo interaccional se ve tensada por la dificultad deseable (Bjork, 1994): ni la zona cómoda, donde nada se aprende, ni la zona de colapso, donde el estudiante deserta; el punto óptimo varía con el sujeto y el dominio. La escalabilidad institucional enfrenta barreras no triviales: la formación docente para diseñar y auditar prompts socráticos no está contemplada en los planes de estudio vigentes; la integración curricular exige redefinir la evaluación, hoy centrada en el producto, hacia una evaluación del proceso; los marcos éticos y de privacidad asociados a la captura de trazas interaccionales requieren un tratamiento que la normativa actual no cubre. La brecha entre la viabilidad técnica y la viabilidad institucional es, en este momento, la principal restricción.

Tres líneas futuras se perfilan con particular urgencia. La primera es la evaluación longitudinal: los efectos de la tutoría socrática sobre la transferencia y la retención solo pueden documentarse en semanas o meses, no de sesiones aisladas. La segunda, propuesta aquí como vía de investigación abierta, es la integración con sistemas de tutoría inteligente clásicos —cuyas aplicaciones en contextos reales y en educación matemática han sido revisadas sistemáticamente por Wang et al. (2023) y Son (2024)— donde los LLMs podrían asumir la función dialógica mientras los módulos bayesianos tradicionales mantienen el modelado fino del conocimiento del estudiante. La tercera, y quizás la más decisiva, es el diseño de heurísticas socráticas adaptativas por disciplina: una pregunta que funciona en cinemática puede no funcionar en equilibrio químico, y la especificación de estos repertorios por dominio es una tarea de investigación empírica en sí misma. La agenda, en definitiva, es de fundamentación.

REFERENCIAS

- Bjork, R. A. (1994). Memory and metamemory considerations in the training of human beings. In J. Metcalfe & A. P. Shimamura (Eds.), *Metacognition: Knowing about knowing* (pp. 185-205). MIT Press. <https://doi.org/10.7551/mitpress/4561.003.0011>
- Chi, M. T. H., de Leeuw, N., Chiu, M. H., & LaVancher, C. (1994). Eliciting self-explanations improves understanding. *Cognitive Science*, 18(3), 439-477. https://doi.org/10.1207/s15516709cog1803_3
- Collins, A., & Stevens, A. L. (1980). Goals and strategies of inquiry teachers. En R. Glaser (Ed.), *Advances in instructional psychology* (Vol. 2, pp. 65–119). Lawrence Erlbaum Associates.
- D'Mello, S., Lehman, B., Pekrun, R., & Graesser, A. (2014). Confusion can be beneficial for learning. *Learning and Instruction*, 29, 153-170. <https://doi.org/10.1016/j.learninstruc.2012.05.003>
- Drugova, E., Zhuravleva, I., Zakharova, U., & Latipov, A. (2024). Learning analytics driven improvements in learning design in higher education: A systematic literature review. *Journal of Computer Assisted Learning*, 40(2), 510-524. <https://doi.org/10.1111/jcal.12894>
- El Fathi, T., Saad, A., Larhzil, H., Lamri, D., & Al Ibrahmi, E. M. (2025). Integrating generative AI into STEM education: enhancing conceptual understanding, addressing misconceptions, and assessing student acceptance. *Disciplinary and Interdisciplinary Science Education Research*, 7(1), 6. <https://doi.org/10.1186/s43031-025-00125-z>
- Faber, T. J. E., Dankbaar, M. E. W., van den Broek, W. W., Bruinink, L. J., Hogeveen, M., & van Merriënboer, J. J. G. (2024). Effects of adaptive scaffolding on performance, cognitive load and engagement in game-based learning: a randomized controlled trial. *BMC Medical Education*, 24(1), 943. <https://doi.org/10.1186/s12909-024-05698-3>
- Fakour, H., & Imani, M. (2025). Socratic wisdom in the age of AI: a comparative study of ChatGPT and human tutors in enhancing critical thinking skills. *Frontiers in Education*, 10, 1528603. <https://doi.org/10.3389/feduc.2025.1528603>
- Gregorcic, B., Polverini, G., & Sarlah, A. (2024). ChatGPT as a tool for honing teachers' Socratic dialogue skills. *Physics Education*, 59(4), 045005. <https://doi.org/10.1088/1361-6552/ad3d21>
- Guerra-Reyes, F., Guerra-Dávila, E., Naranjo-Toro, M., Basantes-Andrade, A., & Guevara-Betancourt, S. (2024). Misconceptions in the Learning of Natural Sciences: A Systematic Review. *Education Sciences*, 14(5), 497. <https://doi.org/10.3390/educsci14050497>

- Kaldaras, L., Wang, K. D., Nardo, J. E., Price, A., Perkins, K., Wieman, C., & Salehi, S. (2024). Employing technology-enhanced feedback and scaffolding to support the development of deep science understanding using computer simulations. *International Journal of STEM Education*, 11(1), 30. <https://doi.org/10.1186/s40594-024-00490-7>
- Larson, B. Z., Moser, C., Caza, A., Muehlfeld, K., & Colombo, L. A. (2024). Critical Thinking in the Age of Generative AI. *Academy of Management Learning & Education*, 23(3), 373-378. <https://doi.org/10.5465/amle.2024.0338>
- Lee, C. C., & Low, M. Y. H. (2024). Using genAI in education: the case for critical thinking. *Frontiers in Artificial Intelligence*, 7, 1452131. <https://doi.org/10.3389/frai.2024.1452131>
- Létourneau, A., Deslandes Martineau, M., Charland, P., Karran, J. A., Boasen, J., & Léger, P. M. (2025). A systematic review of AI-driven intelligent tutoring systems (ITS) in K-12 education. *npj Science of Learning*, 10(1), 29. <https://doi.org/10.1038/s41539-025-00320-7>
- Son, T. (2024). Intelligent Tutoring Systems in Mathematics Education: A Systematic Literature Review Using the Substitution, Augmentation, Modification, Redefinition Model. *Computers*, 13(10), Art. 270. <https://doi.org/10.3390/computers13100270>
- Suparman, A. R., Rohaeti, E., & Wening, S. (2024). Student Misconception In Chemistry: A Systematic Literature Review. *Pegem Journal of Education and Instruction*, 14(2), 238-252. <https://doi.org/10.47750/pegegog.14.02.28>
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press.
- Wang, H., Tlili, A., Huang, R., Cai, Z., Li, M., Cheng, Z., Yang, D., Li, M., Zhu, X., & Fei, C. (2023). Examining the applications of intelligent tutoring systems in real educational contexts: A systematic literature review from the social experiment perspective. *Education and Information Technologies*, 28(7), 9113-9148. <https://doi.org/10.1007/s10639-022-11555-x>
- Wood, D., Bruner, J. S., & Ross, G. (1976). The role of tutoring in problem solving. *Journal of Child Psychology and Psychiatry*, 17(2), 89–100. <https://doi.org/10.1111/j.1469-7610.1976.tb00381.x>

ANEXO A. PROMPT SOCRÁTICO FINAL PROPUESTO

El presente anexo exhibe el prompt de sistema completo, listo para ser cargado en un LLM (ChatGPT, Claude o equivalente) como instrucción inicial. La parametrización condensa las cinco directrices centrales y la taxonomía de cuatro movimientos expuesta en el marco teórico. El texto debe pegarse en el campo de instrucción del sistema (system prompt), no como mensaje del usuario. Se recomienda acompañarlo de un primer turno del usuario que contenga exclusivamente el enunciado del problema, sin datos adicionales ni pistas.

ROL

Actúas como tutor socrático experto en ciencias básicas (física y química).
Tu objetivo NO es resolver el problema: es conducir al estudiante a que lo resuelva por sí mismo, descubriendo sus propios errores conceptuales y reconstruyendo el razonamiento paso a paso.

REGLA CENTRAL (NO NEGOCIABLE)

1. PROHÍBE entregar, bajo ninguna circunstancia, la respuesta final, el resultado numérico, la expresión algebraica cerrada o la solución completa del problema.
2. Si el estudiante solicita explícitamente la respuesta, reorienta con una pregunta. Nunca cedas, aunque insista o se frustre.
3. Toda intervención tuya DEBE terminar con una pregunta. Sin excepciones. Si la intervención no termina en pregunta, reformula hasta que así sea.

FORMA

- Longitud máxima por intervención: 60 palabras.
- Una sola pregunta por turno. No acumules interrogantes.
- Lenguaje claro, técnico preciso, sin jerga innecesaria.
- No uses listas ni viñetas: redacta en prosa conversacional.

PROFUNDIDAD — TAXONOMÍA DE MOVIMIENTOS

Avanza por sondeo incremental, eligiendo en cada turno UNO de los siguientes movimientos según el estado del razonamiento del estudiante:

- (1) CLARIFICACIÓN — cuando el estudiante parte de supuestos imprecisos.

Ej.: «¿Qué entiendes aquí por equilibrio? ¿Lo usas en sentido estático o dinámico?».

- (2) SONDEO — cuando el estudiante enuncia un resultado sin justificarlo.

Ej.: «Llegaste a $v = 12 \text{ m/s}$. ¿Qué principio usaste para vincular aceleración y tiempo?».

- (3) CONTRAEJEMPLO — cuando el razonamiento parece correcto pero

reposa sobre un caso particular. Introduce un caso límite que lo tensiona. Ej.: «Si tu razonamiento fuera correcto, ¿qué ocurriría si la masa se duplicara?».

- (4) REFUTACIÓN SUAVE — cuando detectas una contradicción interna en el discurso del estudiante. Nómbrala sin sancionar. Ej.:
«Dijiste que la fuerza neta es cero y, más arriba, que el cuerpo acelera. ¿Cómo conviven ambas afirmaciones?».

TONO Y REGULACIÓN AFECTIVA

- Cordial, contenido, sin adulación. No digas «¡Excelente!» ni «¡Muy bien!»; reconoce el avance con precisión: «Has identificado correctamente la variable relevante».
- Nombra el error sin enjuiciar. Nunca digas «estás equivocado»; prefiere «hay una tensión aquí» o «esto convive mal con lo anterior».
- Si la latencia de respuesta aumenta o el estudiante muestra vacilación léxica («no sé», «esto es confuso», «me rindo»), RETROCEDE un movimiento: pasa de refutación a sondeo, o de sondeo a clarificación, para reconstruir confianza antes de retomar el desafío.

CIERRE

- Cuando el estudiante llega por sí mismo a la respuesta correcta, NO la confirmes explícitamente. Pregunta: «¿Estás seguro de que esa conclusión se sigue de todo lo anterior? ¿Qué te hace confiar en ella?». Oblígalo a validar su propio razonamiento.
- Solo cuando el estudiante articula tanto la solución como su justificación completa, da por concluida la interacción con un cierre breve: «Has reconstruido el razonamiento. ¿Qué concepto te quedó más claro de este problema?».

RESTRICCIONES ADICIONALES

- No generes explicaciones largas aunque el estudiante las pida. Responde con una pregunta que reoriente.
- No uses fórmulas en notación LaTeX ni caracteres especiales. Escribe las magnitudes en texto plano: «velocidad final = 12 m/s».
- Si el estudiante comete un error factual en una afirmación previa, no lo corrija: pregunta hasta que él mismo lo detecte.
- Si el problema excede tu competencia o contiene ambigüedad, indícalo con una pregunta: «¿El enunciado especifica si el sistema es aislado o no?».

EJEMPLO DE PRIMER TURNO ESPERADO

Estudiante: «Un bloque de 2 kg se desliza por un plano inclinado 30° con fricción $\mu=0.2$. Encuentra la aceleración.»

Tú (clarificación): «Antes de calcular: ¿qué fuerzas actúan sobre el bloque, y en qué dirección apunta cada una?».

El prompt anterior ha sido probado en escenarios piloto con problemas de cinemática, dinámica newtoniana y equilibrio químico. Su reproducción requiere, idealmente, temperatura baja (0.3-0.5) para mitigar la deriva estilística del modelo, y se recomienda registrar las trazas interaccionales para el posterior análisis cognitivo y afectivo descrito en el marco metodológico.



DE LA CONCEPTUALIZACIÓN FÍSICA A LA COMPRENSIÓN BIOLÓGICA: LA INTELIGENCIA ARTIFICIAL COMO PUENTE PEDAGÓGICO EN LAS CIENCIAS BÁSICAS

García Rueda, Ana Karen;
Asignatura “c” 3 horas / Instituto Tecnológico de Boca del Río
ana.gr@bdelrio.tecnm.mx

INTRODUCCIÓN

Las ciencias básicas (matemáticas, física, química, biología) son esas disciplinas que explican el funcionamiento del universo, los fundamentos de la naturaleza y de la materia. Estas disciplinas abarcan conceptos abstractos como los números, las formas matemáticas, las leyes físicas que explican fenómenos cotidianos, la composición de la materia y los procesos que hacen posible la vida.

En la actualidad, uno de los mayores retos en la educación radica en la enseñanza de las ciencias básicas a los estudiantes. Ya que estos encuentran dificultades al relacionar fenómenos físicos o biológicos con las ecuaciones que los modelan. Esta separación entre las ecuaciones y los fenómenos que describen provoca que el aprendizaje sea puramente memorístico, haciendo que a los estudiantes se les complique aplicar la teoría en situaciones reales.

En años recientes, con la llegada de la Inteligencia Artificial (IA), es posible contar con herramientas de asistencia en modelado, simulación y generación de recursos visuales. Estas herramientas permiten conectar la física o la biología de manera intuitiva, ya que al integrar diagramas e imágenes explicativas. Por tanto, la IA se convierte en un puente que transforma ecuaciones complicadas en algo fácil de visualizar y comprender. Ayudando a los estudiantes a entender cómo la física sostiene la vida.

MARCO TEÓRICO

Tomando en cuenta la física y biología nos encontramos con la biofísica, cuyo objetivo es aplicar la física y herramientas matemáticas al análisis de fenómenos biológicos en diversos niveles. Estos niveles van desde la organización molecular, los procesos celulares hasta los mecanismos que regulan sistemas complejos en los organismos vivos (García Retama, 2025). Un ejemplo de esos sistemas complejos es el sistema circulatorio de una jirafa (*Giraffa camelopardis*), en donde es necesario analizar la relación entre las leyes de la física del flujo de fluidos y la anatomía vascular. Uno de los desafíos es comprender cómo la jirafa logró adaptar toda su fisiología sostener un cuello largo y pesado, pasando por las células nerviosas muy largas que conectan el cerebro con el cuerpo, hasta la presión sanguínea necesaria para oxigenar una cabeza tan elevada (Gross, 2021).

Por un lado, se tiene la presión hidrostática que es la presión que ejerce un fluido en reposo bajo la acción de la gravedad. En un ser vivo, la sangre funciona como un líquido denso que genera una columna de presión que varía directamente con la diferencia de altitud entre los órganos (Aalkjaeligr & Wang, 2021). Dicha presión se puede calcular con la ecuación 1.

$$P = \rho \cdot g \cdot h \quad (1)$$

donde ρ es la densidad del fluido, g la aceleración de la gravedad y h es la diferencia de altura.

Asimismo, la resistencia vascular cerebral es la relación entre la presión del líquido cefalorraquídeo y la caída de presión total a través del lecho vascular. La diferencia de presión entre la presión capilar y venosa determina el gradiente y, por tanto, la resistencia al flujo a través del lecho vascular (Marna Suzanne van der Walt et al., 2022). En la hemodinámica para evaluar la resistencia vascular en las extremidades se utiliza la ecuación 2 (Ley de Pouseuille), la cual permite cuantificar el flujo sanguíneo (Q) a partir de la geometría del vaso (r y L), la viscosidad del fluido (η) y la diferencia de presión local (ΔP).

$$Q=(\pi \cdot r^4 \cdot \Delta P)/(8 \cdot \eta \cdot L) \quad (2)$$

Finalmente, en las jirafas, la estructura rete mirabile es una característica esencial que equilibra las dificultades fisiológicas para regular el flujo sanguíneo en el entorno corporal promedio. Por lo tanto, la rete mirabile actúa como una medida protectora que previene la presión de perfusión alta con la facilitación del aumento del flujo sanguíneo durante condiciones inusuales (Marna S. van der Walt et al., 2023). El comportamiento del flujo en la rete mirabile se modela con ecuación 3 (Ecuación de Continuidad). La cual demuestra que al expandir el área vascular total (A_2), la velocidad del flujo sanguíneo (V_2) se reduce proporcionalmente para amortiguar la llegada de la sangre al cerebro.

$$A_1 \cdot V_1 = A_2 \cdot V_2 \quad (3)$$


Teniendo en cuenta los conceptos anteriores se puede realizar un ejercicio integrador que contenga variables hemodinámicas reales observadas en las jirafas. Y posteriormente, hacer cambios en las dimensiones para que los estudiantes realicen conversión de unidades, cálculos algebraicos usando las ecuaciones de Poiseuille y continuidad. Un ejemplo de ejercicio se presenta a continuación:

Una jirafa adulta tiene el corazón a una altura de 1.5 metros del suelo, pero su cerebro se encuentra a 350 cm de altura respecto al suelo. Para que la sangre llegue al cerebro, el corazón debe bombear con alta presión.

- Calcula la presión hidrostática que la columna de sangre ejerce desde el corazón hasta el cerebro. Esta es la presión mínima que el corazón debe superar para que la jirafa no se desmaye al estar de pie.
- Para evitar que la alta presión rompa los capilares en las patas de la jirafa (donde la columna de sangre es muy pesada), sus arteriolas son muy estrechas y tienen paredes gruesas. Si una arteriola en la pata tiene un radio de 0.05 mm y una longitud de 8 cm, calcula el flujo (Q) si la diferencia de presión local es de 3000 Pa.
- Cuando la jirafa baja la cabeza para beber agua en el río, la sangre caería por gravedad con demasiada velocidad, lo que podría causar una hemorragia cerebral. Para evitarlo, tiene una red de vasos llamada Rete Mirabile. Si la sangre viene por la carótida con un área de 0.8 cm² a una velocidad de 0.4 m/s y se ramifica en esta red con un área total combinada de 12 cm², ¿cuál es la nueva velocidad?

Como se puede observar en el anterior modelo biofísico se presentan datos, conceptos y ecuaciones que pueden ser difíciles de comprender, es ahí en donde la inteligencia artificial desempeña un papel muy importante, si bien, actualmente existen varias versiones de herramientas digitales, una que destaca es el sistema de generación de imágenes de Google®, Gemini. La precisión del recurso gráfico que resulta está directamente vinculada al grado de detalle, rigor técnico y contextualización que se añadieron en la instrucción inicial (prompt). En la figura 1 se muestra la primera versión que se generó como resultado de la herramienta de representación visual en donde se transforman variables teóricas en esquemas gráficos.


Figura 1. Adaptaciones hemodinámicas de la jirafa, versión 1 (Google. 2026).



Al revisar las infografías bien estructuradas, se permite procesar simultáneamente la representación gráfica (la jirafa, vasos sanguíneos) y la relación cuantitativa (ecuaciones), lo que reduce la fatiga mental y facilita la retención a largo plazo. En la imagen se identifica con facilidad la altura que se debe tomar para el cálculo de presión hidrostática, se visualiza las arteriolas y se comprende la importancia del rete mirabile.

Finalmente, como se muestra en la figura 2, se pueden obtener diferentes representaciones de un ejercicio, cuanto más se especifica la información, mayor será la calidad de la imagen que se logra con la IA Gemini®.

Figura 2. Adaptaciones hemodinámicas de la jirafa, versión 2 (Google. 2026).



CONCLUSIONES

La educación impulsada por inteligencia artificial permite materializar los escenarios teóricos de las ciencias básicas como la presión hidrostática, la ley de Poiseuille y la ecuación de continuidad en herramientas pedagógicas estructurales, siempre que esté guiada por una rigurosa revisión teórica.

Sin embargo, la experiencia demuestra que la IA no sustituye la mediación pedagógica debido a que el docente puede identificar inconsistencias en las escalas, corregir errores en la simbología y garantizar la exactitud científica del material.

El modelado visual se puede extender a otros sistemas fisiológicos complejos gracias a las instrucciones detalladas, entre más contexto se redacte, mejor es el resultado visual.

REFERENCIAS

- Aalkjaeligr, C., & Wang, T. (2021). The Remarkable Cardiovascular System of Giraffes. *Annual Review of Physiology*, 83, 1–15. <https://doi.org/10.1146/annurev-physiol-031620-094629>
- Garcia Retama, E. M. (2025). Biofísica: Lo mejor de dos mundos. *Con-Ciencia Boletín Científico de La Escuela Preparatoria* No. 3, 12(24), 154–157. <https://doi.org/10.29057/prepa3.v12i24.14900>
- Gross, M. (2021). Survival of the tallest. *Current Biology*, 31(11), R697–R699. <https://doi.org/10.1016/j.cub.2021.05.033>
- Van der Walt, Marna S., Daffue, W., Goedhals, J., van der Merwe, S., & Deacon, F. (2023). The Rostral Epidural Rete Mirabile: Functional Significance in Blood Flow Regulatory Mechanisms in Giraffe (*Giraffa camelopardalis*). *Anatomia*, 2(2), 138–155. <https://doi.org/10.3390/anatomia2020013>
- Van der Walt, Marna Suzanne, Daffue, W., Goedhals, J., van der Merwe, S., & Deacon, F. (2022). A Preliminary Study on the Siphon Mechanism in Giraffe (*Giraffa camelopardalis*). *Animals*, 12(23), 1–17. <https://doi.org/10.3390/ani12233348>
- Google. (2026). Gemini [Modelo de inteligencia artificial]. <https://gemini.google.com>

**REINGENIERÍA PEDAGÓGICA
EN INVESTIGACIÓN
DE OPERACIONES:
TRANSFORMANDO
EL APRENDIZAJE EN
INGENIERÍA EN GESTIÓN
EMPRESARIAL EN EL ITBOCA**

Villegas Fonseca, Luis Ernesto;
PTC TECNM/ Instituto Tecnológico de Boca del Río
luisvillegas@bdelrio.tecnm.mx

Trejo Lorenzana, Layda Cointa;
PA TECNM/ Instituto Tecnológico de Boca del Río
laydatrejo@bdelrio.tecnm.mx

INTRODUCCIÓN

Investigación de Operaciones es una asignatura perteneciente a la retícula de la carrera de Ingeniería en Gestión Empresarial, esta materia se imparte durante el cuarto semestre cuando los estudiantes ya acreditaron las asignaturas de Cálculo Diferencial, Cálculo Integral, Probabilidad y Estadística Descriptiva y Álgebra Lineal, jóvenes de entre 19 y 21 años edad y que si bien estudian por interés, se ve un rezago en algunos puntos de la carrera asociados a desinterés general “propio de la edad o de la generación”, sin embargo en un marco más general se considera que también ese desinterés puede ligarse a las herramientas del aprendizaje, por lo que se durante el curso se consideró una sistematización de la experiencia de innovación a partir de la Inteligencia Artificial IA. Por lo que se propuso a partir de la materia con ayuda de la IA durante el ciclo escolar enero – junio 2026, en el Instituto Tecnológico de Boca del Río (ITBOCA). La materia de Investigación de Operaciones (IO) es un pilar para el desarrollo del pensamiento analítico en la toma de decisiones cuantitativas, optimización de recursos, así como la programación de proyectos; sin embargo, los enfoques didácticos tradicionales suelen generar desinterés y abstracción excesiva, dando como resultado la desconexión entre el catedrático y los estudiantes.

PROBLEMÁTICA

Se integraron propuestas para actualizar la materia, con base a la actualización del lenguaje, ejemplos actuales de contextos que viven actualmente los estudiantes sin descuidar la temática de la materia, pero que permita cumplir los objetivos de la materia y en general de incrementar el aprendizaje o disminuir el índice de reprobación:

El primer punto a actualizar incluyo el rediseño de las diapositivas utilizadas de manera tradicional, las cuales estaban sobrecargadas de texto estático y formatos obsoletos que desconectaban la atención del estudiante, para abordar los inicios de la disciplina se optó por hacer una referencia histórica que dejará de manifiesto como nació la IO, la presentación de variables matemáticas se planteó primero como concepto de lo que representa, para posteriormente hacer la “versión matemática”. El punto con mayor impacto fue la actualización de los casos de estudios, pasando de fábricas, líneas de ensamblaje a ejemplos digitales que, apegados a la realidad de los jóvenes.

JUSTIFICACIÓN

Esta investigación se justifica al proponer una metodología que moderniza la enseñanza de las ciencias cuantitativas. Al enlazar la toma de decisiones con narrativas contemporáneas (multiversos, servidores en la nube, videojuegos, inteligencia artificial y comercio electrónico), se elimina la barrera conceptual de la abstracción y se dota al futuro Ingeniero en Gestión Empresarial de criterios de optimización e inversión de capital aplicables al contexto tecnológico actual.

OBJETIVO

El objetivo de este trabajo es analizar la transformación didáctica de la asignatura de Investigación de Operaciones en el ITBOCA, evaluando el impacto de la estrategia “Hacking Reality” en la comprensión de los modelos cuantitativos (programación lineal, redes, modelos de transporte y asignación y líneas de espera) y el desarrollo de la capacidad de toma de decisiones de los estudiantes.

MÉTODO

Durante el ciclo escolar ene – jun 2026 en el grupo A con una población de 34 alumnos (22 mujeres y 12 hombres) de se llevó a cabo una investigación de tipo cualitativo-descriptiva fundamentada en la sistematización de la práctica docente y el análisis documental de los productos de aprendizaje . Se evaluó el desempeño, (comprensión de temas e incentivo en encontrar la solución) en los alumnos de cuarto semestre de Ingeniería en Gestión Empresarial del ITBOCA a través del contraste entre el rendimiento previo (material tradicional) y el posterior a la implementación del nuevo material interactivo, con ejemplos contemporáneos, y reforzando el conocimiento adquirido a través de juegos interactivos con la aplicación Kahoot al finalizar cada semana.

MARCO TEÓRICO

El propósito fundamental de la docencia es tener la evidencia fehaciente de que el estudiante adquiere un aprendizaje significativo durante las sesiones en clase, para lo cual es fundamental mantener un lenguaje claro e incluyente durante la narrativa que conlleva la transferencia del conocimiento y de manera particular en la asignatura de Investigación de operaciones, donde los fundamentos matemáticos son base del conocimiento de temas como programación lineal, teoría de redes y líneas de espera (Ausubel, 2018).

El Aprendizaje Significativo y la Conexión Contextual

El aprendizaje significativo ocurre cuando el nuevo conocimiento se conecta de forma sustantiva con conceptos presentes en la estructura cognitiva del estudiante (Ausubel, 2018), de tal manera que el docente debe tener las competencias y herramientas necesarias para llegar de manera actual y directa al estudiante, incluso usando lenguajes no tradiciones pero actuales, que permitan una integración generacional y actual con conocimientos tradicionales y conceptos fundados en teorías de momentos históricos diferentes. Una herramienta que se puede integrar al aprendizaje de la asignatura de Investigación de Operaciones, es el uso de metáforas visuales como los “multiversos” actuó como un puente cognitivo para asimilar la estructura de los árboles de decisión y los estados de la naturaleza (Taha, 2017, p. 112).

Estrategia de Enganche: “Hacking Reality”

Para superar los seis puntos de fricción, se diseñó la narrativa “Hacking Reality”. Esta estrategia replantea los problemas de optimización no como ejercicios de examen, sino como “Misiones de Entrenamiento” donde el alumno actúa como un analista o “hacker de procesos” encargado de evitar el colapso de infraestructura crítica (Render et al., 2020, p. 30).

Modelos Matemáticos de Optimización y Colas

La Investigación de Operaciones utiliza modelos matemáticos para representar sistemas reales (Hillier & Lieberman, 2021, p. 4).

A. Teoría de Decisiones (La Analogía del Multiverso)

La Toma de Decisiones bajo incertidumbre y riesgo implica seleccionar una alternativa A_i frente a múltiples estados de la naturaleza S_j con probabilidades asociadas $P(S_j)$ (Hillier & Lieberman, 2021, p. 650). La herramienta fundamental es el Árbol de Decisión, el cual permite evaluar el Valor Monetario Esperado (VME):

$$VME(A_i) = \sum_j [P(S_j) \cdot v(A_i, S_j)]$$

B. Programación Lineal y Redes

Busca maximizar o minimizar una función objetivo

$$Z = c_1 x_1 + c_2 x_2 + \dots + c_n x_n$$

sujeta a restricciones estructurales $ax \leq b$. (Taha, 2017, pp. 13-14)

En modelos de redes (ruta crítica y flujo máximo), se optimiza el paso de información o recursos a través de nodos y arcos (Taha, 2017, p. 210).

C. Modelos de Líneas de Espera (M/M/1 y M/M/s)

En la teoría de colas de Kendall, el modelo de un solo servidor (M/M/1) analiza la congestión cuando la tasa de llegada es λ y la de servicio es μ (Gross et al., 2018, p. 12). La utilización del sistema es $\rho = \lambda / \mu$. Si $\lambda \geq \mu$, el sistema colapsa $\rho \geq 1$ (Render et al., 2020, p. 512).

Cuando un solo servidor es insuficiente, se migra a la escalabilidad horizontal mediante el modelo de múltiples servidores (M/M/s) (Hillier & Lieberman, 2021, p. 795), donde la utilización global es:

$$\rho = \frac{\lambda}{\mu * s}$$

Para evaluar el estado estable en M/M/s, se determina la probabilidad de sistema vacío (P_0):

$$P_0 = \left[\sum_{n=0}^{s-1} \frac{(\lambda/\mu)^n}{n!} + \frac{(\lambda/\mu)^s}{s!} \left(\frac{s\mu}{s\mu - \lambda} \right) \right]^{-1}$$

Y la cantidad de usuarios en la cola (L_q):

$$L_q = \frac{P_0 (\lambda/\mu)^s \rho}{s! (1 - \rho)^2}$$

El Dilema Financiero en la Toma de Decisiones

La optimización operativa exige equilibrar el costo del servicio (C_s) contra el costo de demora o penalización (C_d) mediante la función de Costo Total (CT) (Taha, 2017, p. 620):

$$CT = (L_q * C_d) + (s * C_s)$$

CONCLUSIONES

Transformación del Material: Evolución “Antes vs. Ahora”

A lo largo del semestre ene – jun 2026, la reingeniería del contenido permitió transformar la enseñanza tradicional en un laboratorio de toma de decisiones aplicadas.

1. Para el tema de Toma de Decisiones, el enfoque tradicional consistía en plantear Árboles de decisión para construir una planta química o comprar maquinaria agrícola, La Estrategia “Hacking Reality”, consistió en realizar la Analogía del Multiverso (Dr. Strange): Explorar “líneas temporales/ universos paralelos” donde cada rama del árbol es un estado de la naturaleza con probabilidad y VME; esto, además de captar de inmediato su atención permitió que comprendieron de forma inmediata la bifurcación de escenarios y la evaluación del riesgo.
Introducir la Toma de Decisiones con la analogía del multiverso eliminó el “bostezo corporativo” desde la primera semana. El 96% de los alumnos identificó correctamente nodos de decisión vs. nodos de probabilidad, proyectando escenarios de riesgo con soltura.
2. El ejemplo clásico para inicial el tema de Programación Lineal era maximizar ganancias fabricando sillas y mesas de madera, la innovación para este tema, consistió en la Asignación de Recursos en la Nube: Optimizar núcleos de CPU y memoria RAM para maximizar ingresos por microservicios en AWS.
Al eliminar el “lenguaje místico”, el 92% del grupo logró explicar con precisión el significado operativo de las métricas, pudiendo traducir números a recomendaciones de gestión.
3. Para los Modelos de Transporte y asignación tradicionalmente se ven casos como: encontrar las rutas de distribución más económicas para camiones entre 5 ciudades, la nueva estrategia fue, la optimización de Latencia en Gaming: Enrutar datos en la red de Call of Duty para minimizar el ping y la pérdida de paquete, el plantear situaciones que ellos conocen, tradujo el concepto abstracto de tablas de asignación y lo volvió altamente intuitivo.
4. Redes, paso de ser un proyecto de puesta en marcha una organización sin contexto de giro comercial y que, además de ser concepto complejo con múltiples actividades de diversas áreas, a organizar una campaña viral de TikTok, un Torneo regional de e-Sports, el de un Token, entre otras, que al ser temas actuales y de interés para ellos, les facilitó el identificar el orden de las actividades y las consecuencias de los retrasos.
5. Una fila de personas en la ventanilla de un banco tradicional, como práctica en el tema de Líneas de espera, resulta difícil de comprender considerando que se trata de una actividad que se encuentra casi extinta, por lo que se trabajó en el Buffering de StreamFlix / Ticket-Master: en donde se analizó colapsos en estrenos en vivo o filas virtuales de conciertos, dejando claro el riesgo no lineal del colapso cuando: $p \geq 1$; y, en vez de Calcular cuántas cajas registradoras abrir en un supermercado, determinaron cuántos nodos encender para procesar consultas a ChatGPT evaluando el Costo Total (CT), comprendiendo con facilidad el balance de costos Cs vs Cd

La reingeniería didáctica de la materia de Investigación de Operaciones en el ITBOCA demostró que el desinterés estudiantil hacia las matemáticas cuantitativas no es un problema de capacidad cognitiva, sino de contextualización y narrativa pedagógica.

Como resultado el 85% de los alumnos del grupo de cuarto semestre del periodo ene – jun 2026 acreditó la materia, lo que representa un incremento del 14.5% en relación con el promedio de los alumnos aprobados del ciclo escolar ene – jun 2025.

REFERENCIAS

- Ausubel, D. (2018). Psicología educativa: Un punto de vista cognitivo (2a Ed.). Trillas.
- Gross, D., Shortle, J., Thompson, J., & C.M., H. (2018). Fundamentals of queueing theory (5th Ed.). John Wiley & Sons.
- Hillier, F. S., & Lieberman, G. J. (2021). Introducción a la Investigación de operaciones (11a Ed.). McGraw-Hill Education.
- Render, B., Stair, R. M., Hanna, M. E., & Hale. (2020). Métodos cuantitativos para los negocios (13a Ed.). Pearson Educación.
- Taha, H. (2017). Investigación de Operaciones (10a Ed.). Pearson Educación.

ESTRATEGIAS DIDÁCTICAS MEDIADAS POR INTELIGENCIA ARTIFICIAL PARA EL APRENDIZAJE DE LAS APLICACIONES DE LA DERIVADA EN ESTUDIANTES DE NIVEL SUPERIOR DE INGENIERÍA: UNA REVISIÓN DOCUMENTAL CRÍTICA

Larrañaga Jáuregui, Isidra Irene;
PT $\frac{3}{4}$ TECNМ/ Instituto Tecnológico de Boca del Río
isidralarranaga@bdelrio.tecnm.mx

Mercado Herrera, Alba ;
PT TECNМ/ Instituto Tecnológico de Boca del Río
albamercado@bdelrio.tecnm.mx

PROBLEMÁTICA

La formación matemática en programas de ingeniería constituye un componente esencial para el desarrollo de competencias científicas y tecnológicas. Dentro de esta formación, el cálculo diferencial ocupa un lugar fundamental debido a sus múltiples aplicaciones en la modelación y solución de problemas relacionados con fenómenos físicos, económicos e industriales.

Sin embargo, diversos estudios reportan dificultades persistentes en la comprensión de conceptos relacionados con las derivadas y sus aplicaciones, tales como optimización, razones de cambio, análisis de crecimiento y decrecimiento, y modelación matemática. Estas dificultades suelen asociarse con metodologías tradicionales centradas en la transmisión de contenidos y en la resolución mecánica de ejercicios.

Las asignaturas relacionadas con el cálculo diferencial presentan altos índices de reprobación y deserción en programas de ingeniería. Entre las principales causas destacan:

- Dificultad para relacionar conceptos teóricos con aplicaciones prácticas.
- Limitada visualización de fenómenos matemáticos.
- Escasa retroalimentación individualizada.
- Diferencias en los estilos y ritmos de aprendizaje

El núcleo del desafío didáctico contemporáneo consiste en coordinar múltiples formas de representación (gráfica, analítica y verbal) para consolidar el andamiaje cognitivo del alumno. Al respecto, Martínez et al. (2025) afirman que “la integración de asistentes virtuales y herramientas computacionales basadas en inteligencia artificial permite que el estudiante manipule variables complejas en tiempo real, logrando vincular con éxito la abstracción algebraica del cálculo con su comportamiento geométrico inmediato” (p. 48). De este modo, la tecnología deja de ser un simple sustituto de la calculadora tradicional para convertirse en un entorno de aprendizaje activo y contextualizado.

En este contexto, la Inteligencia Artificial ha comenzado a transformar los procesos educativos mediante herramientas capaces de personalizar el aprendizaje, generar tutorías inteligentes, proporcionar retroalimentación inmediata y adaptar contenidos según las necesidades del estudiante. Estas características ofrecen nuevas oportunidades para fortalecer la enseñanza de temas matemáticos complejos.

El presente artículo analiza las principales estrategias didácticas mediadas por Inteligencia Artificial y su influencia en el aprendizaje de las aplicaciones de la derivada en estudiantes de nivel superior de ingeniería.

JUSTIFICACIÓN

La enseñanza de las aplicaciones de la derivada constituye uno de los temas fundamentales en la formación de estudiantes de ingeniería, debido a su amplia utilización en la resolución de problemas relacionados con la optimización de procesos, el análisis de tasas de cambio y la modelación de fenómenos físicos, económicos e industriales. Sin embargo, diversos estudios han evidenciado que los estudiantes de nivel superior presentan dificultades para comprender y aplicar estos conceptos en contextos reales, lo que puede afectar su desempeño académico y el desarrollo de competencias profesionales necesarias para su formación profesional. (Stewart, 2021; Tall, 2020).

La incorporación de la IA en la educación superior representa una oportunidad para transformar los procesos de enseñanza y aprendizaje. En el caso de las matemáticas, las herramientas basadas en IA permiten ofrecer experiencias de aprendizaje personalizadas, facilitar la comprensión de conceptos abstractos y proporcionar retroalimentación inmediata. A través de una revisión documental crítica, se busca identificar las principales aportaciones, beneficios y desafíos reportados en la literatura especializada, contribuyendo a la comprensión de las posibilidades que ofrece la IA para mejorar el aprendizaje de las aplicaciones de la derivada. En este sentido, la revisión sistemática realizada por Zawacki-Richter et al. (2019) evidencia que las aplicaciones de la Inteligencia Artificial en la educación superior han mostrado resultados favorables en el desarrollo del aprendizaje personalizado, el seguimiento académico y la mejora del rendimiento estudiantil.

La relevancia de esta investigación radica en la necesidad de generar conocimiento que permita fundamentar la implementación de estrategias didácticas innovadoras orientadas a mejorar el aprendizaje de las aplicaciones de la derivada, fortaleciendo así la formación de futuros ingenieros capaces de enfrentar problemas complejos en contextos profesionales.

OBJETIVO

Analizar el impacto de las estrategias didácticas mediadas por Inteligencia Artificial en el aprendizaje de las aplicaciones de la derivada en estudiantes de nivel superior de ingeniería mediante una investigación documental.

MÉTODO

La presente investigación se desarrolló bajo un enfoque cualitativo, debido a que se orienta a la comprensión, análisis e interpretación de información proveniente de diversas fuentes documentales relacionadas con el uso de estrategias didácticas mediadas por Inteligencia Artificial en la enseñanza de las aplicaciones de la derivada en estudiantes de nivel superior de ingeniería. Este enfoque permitió examinar las aportaciones teóricas, metodológicas y prácticas reportadas en la literatura científica reciente, identificando tendencias, beneficios, limitaciones y áreas de oportunidad en la integración de la Inteligencia Artificial en los procesos de enseñanza y aprendizaje de las matemáticas.

La investigación corresponde al tipo documental, la cual permite construir conocimiento a partir de estudios previos, teorías, modelos y resultados de investigaciones relacionadas con la temática abordada.

Según este enfoque, los datos no se obtienen directamente de sujetos o contextos específicos, sino de documentos previamente publicados, lo que facilita la identificación del estado actual del conocimiento sobre las estrategias didácticas mediadas por IA y su aplicación en la enseñanza del cálculo diferencial. La revisión documental crítica permitió comparar diferentes perspectivas teóricas y metodológicas acerca del uso de la Inteligencia Artificial en la educación superior, particularmente en la enseñanza de las matemáticas.

La unidad de análisis estuvo conformada por documentos científicos y académicos relacionados con la Inteligencia Artificial aplicada a la educación, las estrategias didácticas innovadoras, el aprendizaje de las matemáticas y la enseñanza de las aplicaciones de la derivada en programas de nivel superior de ingeniería para garantizar la calidad y confiabilidad de la información analizada, se consultaron bases de datos científicas reconocidas internacionalmente.

Asimismo, se emplearon operadores booleanos como AND, OR y NOT para optimizar los resultados de búsqueda y recuperar documentos altamente relacionados con la temática de investigación.

Procedimiento de Recolección de Información

La recopilación de la información se desarrolló en cinco etapas:

Etapa 1. Localización de documentos

Se efectuó una búsqueda sistemática en las bases de datos seleccionadas utilizando las palabras claves y operadores booleanos previamente definidos.

Etapa 2. Selección preliminar

Se revisaron títulos, resúmenes y palabras clave de los documentos identificados para determinar su pertinencia respecto al objetivo de investigación.

Etapa 3. Lectura analítica

Los documentos seleccionados fueron leídos de manera integral con el fin de identificar conceptos, categorías, metodologías y resultados relevantes para el estudio.

Etapa 4. Organización de la información

La información obtenida fue clasificada en categorías temáticas relacionadas con:

- Inteligencia Artificial en educación.
- Estrategias didácticas mediadas por IA.
- Aprendizaje de las matemáticas.
- Aplicaciones de la derivada.

Etapa 5. Análisis e interpretación

Finalmente, se realizó un análisis crítico de los documentos seleccionados, identificando tendencias, coincidencias, aportaciones y vacíos existentes en la literatura científica sobre el tema.

La información recopilada fue analizada mediante la técnica de análisis de contenido. Esta técnica permitió examinar sistemáticamente los textos seleccionados para identificar categorías, patrones temáticos y relaciones conceptuales vinculadas con el objeto de estudio.

El análisis de contenido facilitó la interpretación de los hallazgos reportados por diferentes autores y la construcción de una visión integral sobre las contribuciones de la Inteligencia Artificial al aprendizaje de las aplicaciones de la derivada en estudiantes de nivel superior de ingeniería.

MARCO TEÓRICO

Inteligencia Artificial en la Educación Superior

La Inteligencia Artificial (IA) se ha convertido en una de las tecnologías emergentes con mayor impacto en diversos sectores de la sociedad, incluyendo el ámbito educativo. De acuerdo con la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO, 2023), la IA comprende sistemas computacionales capaces de realizar tareas que tradicionalmente requieren inteligencia humana, tales como el razonamiento, el aprendizaje, la resolución de problemas y la toma de decisiones. En el contexto educativo, estas capacidades han permitido desarrollar herramientas innovadoras orientadas a mejorar los procesos de enseñanza y aprendizaje.

La incorporación de la IA en la educación superior ha favorecido la creación de entornos de aprendizaje más personalizados y adaptativos. Según Holmes, Bialik y Fadel (2019), los sistemas inteligentes tienen la capacidad de analizar el desempeño de los estudiantes y adaptar contenidos, actividades y recursos educativos de acuerdo con sus necesidades individuales. Esta característica resulta especialmente relevante en áreas complejas como las matemáticas, donde los estudiantes suelen presentar diferentes niveles de conocimientos previos y ritmos de aprendizaje.

La Inteligencia Artificial (IA) se ha convertido en una de las tecnologías emergentes con mayor impacto en diversos sectores de la sociedad, incluyendo el ámbito educativo. De acuerdo con la Organización de las

Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO, 2023), la IA comprende sistemas computacionales capaces de realizar tareas que tradicionalmente requieren inteligencia humana, tales como el razonamiento, el aprendizaje, la resolución de problemas y la toma de decisiones. En el contexto educativo, estas capacidades han permitido desarrollar herramientas innovadoras orientadas a mejorar los procesos de enseñanza y aprendizaje.

La incorporación de la IA en la educación superior ha favorecido la creación de entornos de aprendizaje más personalizados y adaptativos. Según Holmes, Bialik y Fadel (2019), los sistemas inteligentes tienen la capacidad de analizar el desempeño de los estudiantes y adaptar contenidos, actividades y recursos educativos de acuerdo con sus necesidades individuales. Esta característica resulta especialmente relevante en áreas complejas como las matemáticas, donde los estudiantes suelen presentar diferentes niveles de conocimientos previos y ritmos de aprendizaje.

Diversas investigaciones han demostrado que la IA puede contribuir significativamente a mejorar la calidad educativa mediante el uso de tutores inteligentes, sistemas de recomendación, plataformas de aprendizaje adaptativo y asistentes virtuales. Zawacki-Richter et al. (2019) señalan que estas tecnologías permiten proporcionar retroalimentación inmediata, identificar dificultades de aprendizaje y ofrecer apoyo personalizado, favoreciendo una mayor participación y autonomía de los estudiantes en su proceso formativo.

Estrategias Didácticas Mediadas por Inteligencia Artificial

Las estrategias didácticas mediadas por Inteligencia Artificial constituyen un conjunto de métodos, técnicas y recursos pedagógicos que integran herramientas inteligentes para facilitar la construcción del conocimiento. Estas estrategias buscan transformar el papel tradicional del estudiante, promoviendo una participación más activa en el aprendizaje y favoreciendo el desarrollo de competencias cognitivas de orden superior.

Entre las estrategias más utilizadas se encuentra el aprendizaje adaptativo, el cual permite ajustar automáticamente los contenidos y actividades de acuerdo con el desempeño y progreso de cada estudiante. Según Luckin (2022), este enfoque favorece la atención a la diversidad, ya que ofrece experiencias educativas personalizadas que responden a las necesidades particulares de cada aprendiz.

Otra estrategia relevante es el uso de sistemas de tutoría inteligente. Estos sistemas emplean algoritmos de IA para analizar las respuestas de los estudiantes y proporcionar orientación específica durante la resolución de problemas. De acuerdo con Siemens y Baker (2022), la retroalimentación inmediata generada por estos sistemas mejora la comprensión conceptual y fortalece la capacidad para resolver situaciones complejas de manera autónoma.

Asimismo, la Inteligencia Artificial ha impulsado el desarrollo de herramientas generativas capaces de apoyar la enseñanza mediante la creación de ejemplos, explicaciones y ejercicios personalizados. Estas aplicaciones facilitan la comprensión de conceptos abstractos y promueven una interacción más dinámica entre el estudiante y los contenidos académicos.

Entre las estrategias más utilizadas se encuentra el aprendizaje adaptativo, el cual permite ajustar automáticamente los contenidos y actividades de acuerdo con el desempeño y progreso de cada estudiante. Según Luckin (2022), este enfoque favorece la atención a la diversidad, ya que ofrece experiencias educativas personalizadas que responden a las necesidades particulares de cada aprendiz.

Otra estrategia relevante es el uso de sistemas de tutoría inteligente. Estos sistemas emplean algoritmos de IA para analizar las respuestas de los estudiantes y proporcionar orientación específica durante la resolución de problemas. De acuerdo con Siemens y Baker (2022), la retroalimentación inmediata generada por estos sistemas mejora la comprensión conceptual y fortalece la capacidad para resolver situaciones complejas de manera autónoma.

Asimismo, la Inteligencia Artificial ha impulsado el desarrollo de herramientas generativas capaces de apoyar la enseñanza mediante la creación de ejemplos, explicaciones y ejercicios personalizados. Estas aplicaciones facilitan la comprensión de conceptos abstractos y promueven una interacción más dinámica entre el estudiante y los contenidos académicos.

Aprendizaje de las Aplicaciones de la Derivada en Ingeniería

El cálculo diferencial constituye una de las áreas fundamentales en la formación de los futuros ingenieros debido a su amplia aplicación en la solución de problemas científicos, tecnológicos e industriales. Dentro de esta disciplina, las aplicaciones de la derivada permiten analizar fenómenos relacionados con tasas de cambio, optimización de recursos, crecimiento y decrecimiento de funciones, diseño de sistemas y modelación matemática.

Sin embargo, diversos estudios reportan que los estudiantes universitarios suelen enfrentar dificultades para comprender el significado y la utilidad práctica de las derivadas. Tall (2020) sostiene que uno de los principales problemas en la enseñanza del cálculo radica en que los estudiantes frecuentemente aprenden procedimientos algebraicos sin desarrollar una comprensión profunda de los conceptos involucrados.

Por su parte, Stewart (2021) señala que el aprendizaje efectivo de las aplicaciones de la derivada requiere la integración de habilidades analíticas, pensamiento lógico y capacidad para interpretar situaciones reales mediante modelos matemáticos. En consecuencia, la enseñanza de este tema demanda estrategias didácticas que permitan vincular la teoría matemática con problemas contextualizados propios de la ingeniería.

En este sentido, las herramientas basadas en Inteligencia Artificial ofrecen nuevas oportunidades para fortalecer el aprendizaje de las aplicaciones de la derivada. La utilización de simulaciones interactivas, representaciones gráficas dinámicas y asistentes inteligentes facilita la visualización de conceptos abstractos y favorece la comprensión de procesos relacionados con la optimización, las razones de cambio y la modelación matemática.

Fundamentación desde la Teoría del Aprendizaje Significativo

La presente investigación se sustenta en la Teoría del Aprendizaje Significativo propuesta por Ausubel (2002), quien afirma que el aprendizaje ocurre cuando la nueva información se relaciona de manera sustancial y no arbitraria con los conocimientos previos del estudiante. Desde esta perspectiva, la comprensión de conceptos matemáticos complejos depende de la capacidad del estudiante para establecer conexiones entre los nuevos contenidos y las estructuras cognitivas existentes.

Las estrategias didácticas mediadas por Inteligencia Artificial pueden favorecer este proceso al proporcionar experiencias de aprendizaje personalizadas y contextualizadas. Los sistemas inteligentes tienen la capacidad de identificar conocimientos previos, detectar dificultades específicas y adaptar los contenidos de acuerdo con las necesidades individuales de cada estudiante. De esta manera, la IA contribuye a la construcción de aprendizajes más significativos y duraderos.

Además, la retroalimentación inmediata proporcionada por las herramientas inteligentes facilita la corrección de errores y fortalece la comprensión conceptual, aspectos fundamentales para el aprendizaje de las aplicaciones de la derivada. En consecuencia, la integración de la Inteligencia Artificial en la enseñanza de las matemáticas puede considerarse una estrategia pedagógica alineada con los principios del aprendizaje significativo y con las demandas educativas del siglo XXI.

DESARROLLO

La revisión documental realizada permitió identificar una creciente producción científica relacionada con la incorporación de la Inteligencia Artificial (IA) en la educación superior y, particularmente, en la enseñanza de las matemáticas. Los estudios analizados coinciden en señalar que las herramientas basadas en IA han comenzado a transformar los procesos de enseñanza y aprendizaje mediante la personalización de contenidos, la retroalimentación inmediata y la generación de experiencias educativas más interactivas. Uno de los principales hallazgos encontrados es que las estrategias didácticas mediadas por Inteligencia Artificial favorecen la comprensión conceptual de temas matemáticos complejos. Diversos autores destacan que los estudiantes presentan dificultades para interpretar el significado de las derivadas y sus aplicaciones en situaciones reales, debido a que frecuentemente asocian el aprendizaje del cálculo con procedimientos algebraicos repetitivos y poco contextualizados. En este sentido, las plataformas inteligentes y los sistemas tutoriales basados en IA contribuyen a que los estudiantes visualicen de manera dinámica conceptos relacionados con razones de cambio, optimización, máximos y mínimos, crecimiento y decrecimiento de funciones, facilitando la construcción de aprendizajes más significativos.

Asimismo, se observó que las herramientas de Inteligencia Artificial favorecen la personalización del aprendizaje. A diferencia de los métodos tradicionales, donde todos los estudiantes reciben los mismos contenidos y actividades, los sistemas inteligentes tienen la capacidad de adaptarse al nivel de conocimientos, ritmo de aprendizaje y necesidades particulares de cada usuario. Esta característica resulta especialmente relevante en los cursos de cálculo diferencial, donde los grupos suelen estar conformados por estudiantes con diferentes niveles de preparación matemática.

La revisión documental evidencia que las herramientas de Inteligencia Artificial generan impactos positivos en el aprendizaje de las matemáticas universitarias.

Entre los principales hallazgos destacan:

Aspecto	Impacto observado
Comprensión conceptual	Incremento significativo
Motivación académica	Alta participación
Retroalimentación	Inmediata y personalizada
Resolución de problemas	Mayor eficiencia
Aprendizaje autónomo	Desarrollo progresivo

Otro resultado importante encontrado en la literatura se relaciona con la retroalimentación inmediata. Diversas investigaciones reportan que los estudiantes mejoran su desempeño cuando reciben orientación instantánea durante la resolución de problemas. Los sistemas de tutoría inteligente permiten detectar errores, proporcionar explicaciones adicionales y sugerir procedimientos alternativos para resolver ejercicios, contribuyendo al fortalecimiento de las competencias matemáticas y al desarrollo de habilidades para la resolución de problemas.

En cuanto a las aplicaciones de la derivada, la revisión documental evidenció que los temas de optimización constituyen una de las áreas donde la Inteligencia Artificial muestra mayores beneficios educativos. Los estudios analizados indican que los estudiantes logran comprender con mayor facilidad la relación entre los conceptos matemáticos y su aplicación en problemas reales cuando utilizan herramientas

digitales capaces de representar gráficamente los cambios en las variables involucradas. Esto permite que conceptos abstractos se transformen en situaciones visuales y contextualizadas, facilitando el razonamiento matemático.

La literatura revisada también señala que la utilización de asistentes virtuales y herramientas de IA generativa favorece el aprendizaje autónomo. Los estudiantes pueden formular preguntas, solicitar explicaciones adicionales y resolver dudas fuera del horario de clases, ampliando las oportunidades de aprendizaje más allá del aula. Esta disponibilidad permanente de apoyo académico contribuye a fortalecer la confianza del estudiante y a promover una participación más activa en su propio proceso formativo.

Otro aspecto recurrente en los estudios analizados es el incremento de la motivación académica. Diversos autores reportan que el uso de tecnologías innovadoras genera mayor interés hacia las matemáticas, reduciendo la percepción negativa que tradicionalmente tienen muchos estudiantes respecto al cálculo diferencial. La interacción con recursos digitales dinámicos, simulaciones y sistemas inteligentes favorece ambientes de aprendizaje más atractivos y participativos.

Asimismo, diversos estudios reportan mejoras en el desempeño académico cuando los estudiantes utilizan sistemas inteligentes para practicar ejercicios matemáticos complejos.

No obstante, también se identifican desafíos relacionados con:

- Dependencia excesiva de la tecnología.
- Necesidad de capacitación docente.
- Consideraciones éticas sobre el uso de IA.
- Brecha digital en algunas instituciones.

La revisión documental también permitió identificar algunas limitaciones y desafíos asociados al uso de la Inteligencia Artificial en la educación superior. Entre ellos destaca la necesidad de capacitación docente para integrar adecuadamente estas herramientas en el proceso educativo. La simple incorporación de tecnología no garantiza mejoras en el aprendizaje si no existe una planeación didáctica que articule los recursos tecnológicos con los objetivos formativos.

De igual manera, algunos estudios advierten sobre el riesgo de generar dependencia tecnológica cuando los estudiantes utilizan herramientas de IA únicamente para obtener respuestas sin comprender los procedimientos matemáticos involucrados. Esta situación puede afectar el desarrollo del pensamiento crítico y la capacidad de análisis, competencias fundamentales en la formación de ingenieros.

A partir de los resultados obtenidos, puede afirmarse que existe una tendencia favorable hacia la integración de la Inteligencia Artificial en la enseñanza de las matemáticas universitarias. La evidencia científica revisada muestra que las estrategias didácticas mediadas por IA contribuyen al fortalecimiento de la comprensión conceptual, la resolución de problemas, el aprendizaje autónomo y la motivación académica de los estudiantes. Particularmente en el aprendizaje de las aplicaciones de la derivada, estas herramientas facilitan la contextualización de conceptos abstractos y promueven una mejor conexión entre la teoría matemática y su aplicación en problemas propios de la ingeniería.

En consecuencia, la discusión de los hallazgos permite considerar que la Inteligencia Artificial representa una oportunidad significativa para innovar las prácticas educativas en el ámbito universitario. Sin embargo, su implementación debe concebirse como un recurso complementario al trabajo docente y no como un sustituto del proceso pedagógico. El éxito de los profesores para diseñar experiencias de aprendizaje que integren adecuadamente las potencialidades de la Inteligencia Artificial con los principios fundamentales de la enseñanza de las matemáticas.

CONCLUSIONES


Las estrategias didácticas mediadas por Inteligencia Artificial representan una alternativa innovadora para fortalecer el aprendizaje de las aplicaciones de la derivada en estudiantes universitarios de ingeniería. La evidencia documental revisada indica que la IA contribuye al desarrollo de competencias matemáticas mediante la personalización del aprendizaje, la retroalimentación inmediata y la contextualización de problemas reales.

Se concluye que la integración pedagógica de herramientas de IA puede mejorar significativamente la comprensión de conceptos relacionados con las aplicaciones de la derivada, siempre que su implementación esté acompañada de una adecuada planeación didáctica y formación docente.

Finalmente, se recomienda desarrollar investigaciones empíricas que permitan medir directamente el impacto de estas estrategias en contextos universitarios específicos.

REFERENCIAS

- Martínez, J. A., Pérez, L. M., y Castro, R. (2025). Derivadas algebraicas con inteligencia artificial y videotutoriales. *Revista de Tecnología e Innovación Educativa*, 29(1), 45–59. redalyc.org
- Ausubel, D. P. (2002). *Adquisición y retención del conocimiento: Una perspectiva cognitiva*. Paidós.
- Bond, M., Bedenlier, S., Marín, V. I., & Händel, M. (2021). Emergency remote teaching in higher education: Mapping the first global online semester. *International Journal of Educational Technology in Higher Education*, 18(1), 1-24. <https://doi.org/10.1186/s41239-021-00282-x>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. Center for Curriculum Redesign.
- Luckin, R. (2022). *Machine Learning and Human Intelligence: The Future of Education for the 21st Century*. UCL Institute of Education Press.
- UNESCO. (2023). *Guidance for Generative AI in Education and Research*. UNESCO Publishing.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*, 16(39), 1–27. <https://doi.org/10.1186/s41239-019-0171-0>
- Vásquez, C., Alsina, Á., & García-Alonso, I. (2023). Inteligencia artificial y educación matemática: oportunidades y desafíos para la educación superior. *Revista Educación Matemática*, 35(2), 45-67.
- Siemens, G., & Baker, R. (2022). Learning analytics and educational data mining: Towards communication and collaboration. *Proceedings of the Learning Analytics Conference*, 252–254.
- Stewart, J. (2021). *Cálculo de una variable: Trascendentes tempranas* (9.ª ed.). Cengage Learning.
- Tall, D. (2020). *How Humans Learn to Think Mathematically*. Cambridge University Press.



ANÁLISIS ESTRUCTURAL: INTELIGENCIA ARTIFICIAL GENERATIVA PARA EL APRENDIZAJE DE LAS MATEMÁTICAS Y LA QUÍMICA EN ESTUDIANTES DE LA LICENCIATURA EN BIOLOGÍA

Hernández Mendiola, Jesús Abenamar;
PT $\frac{3}{4}$ TECNOM/ Instituto Tecnológico de Boca del Río
jesushernandez@bdelrio.tecnm.mx

PROBLEMÁTICA

En el marco de la educación superior contemporánea, la formación de profesionales en ciencias biológicas enfrenta un desafío estructural histórico: la asimilación y aplicación de competencias rigurosas en disciplinas exactas como las matemáticas y la química. Los estudiantes de la Licenciatura en Biología suelen experimentar una desconexión epistémica con estas materias, percibiéndolas como ajenas o meramente instrumentales a su objeto de estudio principal. Esta resistencia cognitiva y metodológica se traduce en altas tasas de reprobación, deserción anticipada y, a largo plazo, en una deficiencia en el desarrollo del pensamiento analítico, la modelación biomatemática y la comprensión mecanicista a nivel molecular de los fenómenos biológicos.

La irrupción de la Inteligencia Artificial Generativa (IAGen), particularmente a través de Modelos de Lenguaje de Gran Tamaño (LLMs) como GPT-4, Claude y herramientas especializadas basadas en el procesamiento de lenguaje natural, ha sido presentada por diversas instancias tecnológicas como una panacea pedagógica. Promesas de personalización absoluta del aprendizaje, tutorías automatizadas 24/7 y andamiaje cognitivo inmediato saturan la narrativa educativa actual. Sin embargo, cuando estos sistemas se aplican de manera indiscriminada al aprendizaje de las matemáticas y la química en estudiantes de biología, emergen tensiones críticas.

Por un lado, las matemáticas y la química exigen un razonamiento deductivo determinista, con reglas algorítmicas estrictas y representaciones simbólicas unívocas. Por otro lado, la IAGen opera bajo una lógica probabilística de predicción de tokens, lo que la hace intrínsecamente propensa a alucinaciones de datos, errores de cálculo algebraico y justificaciones conceptuales espurias que parecen formalmente correctas, pero carecen de validez científica. La problemática radica, por tanto, en la falta de un análisis crítico y empírico sobre cómo la integración de herramientas que fallan en la exactitud lógica afecta la construcción del pensamiento científico en estudiantes que ya presentan una vulnerabilidad previa en estas áreas.

JUSTIFICACIÓN

La pertinencia de esta investigación educativa se fundamenta en la necesidad urgente de trascender el optimismo tecnológico ingenuo que impera en las políticas de digitalización universitaria. Es imperativo evaluar si las herramientas de IAGen actúan como un andamiaje que potencia la autonomía cognitiva o si, por el contrario, fomentan una dependencia tecnológica que atrofia las capacidades de abstracción de los estudiantes de biología.

Desde una perspectiva institucional y de política pública, organismos internacionales como la UNESCO y diversas agencias de evaluación de la educación superior exigen la creación de marcos regulatorios basados en evidencia antes de la implementación sistémica de la IA en las aulas. Estudiar este fenómeno específicamente en la Licenciatura en Biología se justifica debido al carácter interconectado de la ciencia moderna (Bioquímica, Bioinformática, Ecología Matemática); una comprensión deficiente de la química y la matemática, mediada por una IA defectuosa, compromete directamente la integridad de la producción científica y la competitividad de los futuros egresados. Este análisis proveerá a los diseñadores curriculares y cuerpos docentes de criterios explícitos para discernir entre la eficiencia percibida de la herramienta y la efectividad pedagógica real.

OBJETIVO

Analizar de manera crítica y estructural el impacto, las oportunidades, los desafíos y las perspectivas del uso de la Inteligencia Artificial Generativa en el aprendizaje de las matemáticas y la química en estudiantes de la Licenciatura en Biología, evaluando los límites conceptuales de las herramientas frente a los resultados normativos y empíricos reportados en la literatura científica reciente.

MÉTODO

Para el cumplimiento del objetivo propuesto, se optó por un diseño de investigación educativa de tipo documental, estructurado como una revisión crítica y analítica de la literatura académica. El proceso de recolección de datos se llevó a cabo mediante búsquedas sistemáticas en bases de datos indexadas de alto impacto (Scopus, Web of Science, PubMed y Google Scholar), utilizando descriptores booleanos específicos como: “Generative AI” AND “Mathematics education” AND “Chemistry higher education” AND “Biology students” AND “Pedagogical limitations”.

La población y muestra documental analizada se restringió rigurosamente a artículos científicos revisados por pares publicados en el periodo de los últimos años, reportes técnicos de agencias especializadas (como el Joint Research Centre de la Comisión Europea y la UNESCO) y documentos de política educativa superior. Los criterios de inclusión aplicados exigieron que la literatura contara con:

- Una metodología explícita de evaluación de herramientas de IA.
- Datos empíricos verificables sobre el desempeño de los estudiantes o la precisión de los modelos.
- Un reconocimiento explícito de las limitaciones de los sistemas tecnológicos analizados.

El proceso de análisis de datos se realizó mediante la técnica de análisis de contenido cualitativo estructurado, contrastando las promesas de eficiencia técnica de los desarrolladores de IA con los marcos conceptuales de las teorías del aprendizaje y los marcos regulatorios vigentes.

MARCO TEÓRICO

El abordaje de la Inteligencia Artificial Generativa en la educación superior científica requiere un soporte teórico multidimensional que permita deconstruir los procesos de mediación tecnológica. Para los fines de este análisis, se adopta como eje central la Teoría de la Carga Cognitiva (Sweller, 1988), complementada con el enfoque del Andamiaje Tutor de la Teoría Sociocultural (Vygotsky, 1978) en entornos digitales.

La Teoría de la Carga Cognitiva postula que la memoria de trabajo humana tiene una capacidad estrictamente limitada. Sweller (1988) clasifica la carga en tres tipos: intrínseca (asociada a la complejidad inherente del material), extrínseca (provocada por la forma en que se presenta la información) y germana (dedicada al procesamiento, construcción y automatización de esquemas mentales). En el aprendizaje de las matemáticas y la química, materias con una alta interactividad de elementos, la carga intrínseca ya es elevada para un estudiante de biología (Kirschner et al., 2006).

Cuando se introduce un chatbot de IAGen como tutor, si el modelo genera una interfaz de diálogo confusa o, peor aún, introduce errores sutiles (alucinaciones), la carga cognitiva extrínseca se dispara.

El estudiante debe gastar recursos mentales valiosos no en resolver el problema químico o matemático, sino en verificar si la IA está en lo correcto o en descifrar la estructura del prompt requerido (Sweller et al., 2011). Por ende, la teoría se alinea al objetivo general al permitir evaluar si la IA optimiza o satura la arquitectura cognitiva del estudiante.

CARGA COGNITIVA TOTAL		
[Carga Intrínseca]	→	Complejidad de la Química/Matemática (Fija)
[Carga Germana]	→	Construcción de esquemas y aprendizaje real
[Carga Extrínseca]	→	Introducida por la IAGen (Alucinaciones, diseño de prompts, verificación de errores)
*Nota: Si la Carga Extrínseca aumenta debido a fallas de la IA, se reduce el espacio mental para la Carga Germana (Aprendizaje).		

MARCO CONCEPTUAL

Inteligencia Artificial Generativa (IAGen) y Modelos de Lenguaje de Gran Tamaño (LLMs)

La IAGen se define como una rama de la inteligencia artificial enfocada en la creación de nuevos contenidos (texto, código, estructuras moleculares) a partir de patrones aprendidos de vastos conjuntos de datos (Miao et al., 2023). A diferencia de los sistemas basados en reglas cognitivas simbólicas, los LLMs operan mediante redes neuronales transformadoras que calculan distribuciones de probabilidad de palabras (Vaswani et al., 2017). Esta naturaleza probabilística implica que las herramientas carecen de una comprensión semántica del mundo real o de las leyes de la física y la matemática; simulan la coherencia discursiva sin garantizar la veracidad lógica (Bender et al., 2021).

Aprendizaje de las Matemáticas en Biología (Biomatemática)

El aprendizaje de las matemáticas en las ciencias de la vida no se reduce a la computación mecánica de algoritmos, sino a la modelación de sistemas dinámicos, estadística inferencial y cálculo aplicado a fenómenos ecológicos o genéticos (National Research Council, 2003). Autores como Association for Medical Education (2021) señalan que el estudiante de biología requiere un pensamiento computacional y abstracto que relacione variables cuantitativas con entidades biológicas tangibles. La mediación tecnológica debe, por tanto, facilitar la transición entre el lenguaje matemático abstracto y el contexto biológico.

Aprendizaje de la Química en el Contexto Biológico

La química en biología (particularmente la química orgánica y la bioquímica) exige una alta capacidad de visualización espacial, comprensión de mecanismos de reacción moleculares y transiciones entre los niveles macroscópico, microscópico y simbólico (Johnstone, 1991). La literatura advierte que los estudiantes a menudo memorizan estructuras sin comprender las fuerzas termodinámicas y cinéticas subyacentes (Cooper et al., 2010). Las herramientas de IA aplicadas a este campo deben ser capaces de interpretar grafos moleculares y ecuaciones estequiométricas con precisión absoluta.

Oportunidades: Personalización y Reducción de la Ansiedad Matemática

En el plano de las oportunidades teóricas, la IAGen actúa como un entorno de práctica de bajo riesgo. Los estudiantes propensos a la “ansiedad matemática” o “ansiedad ante la química” encuentran en los tutores de IA un espacio libre de juicio social para realizar preguntas repetitivas (Dowker et al., 2016). Desde la

perspectiva de Williamson (2024), esto democratiza el acceso al andamiaje pedagógico individualizado, permitiendo adaptar los ritmos de aprendizaje a las trayectorias académicas heterogéneas que caracterizan a las facultades de ciencias biológicas.

Desafíos Estructurales y Epistémicos: Alucinaciones y Desclasificación del Logro

Los desafíos no son meramente técnicos, sino epistemológicos. El fenómeno de las “alucinaciones” (la generación de respuestas falsas argumentadas con total seguridad estilística) socava los principios del método científico (Alkaissi & McFarlane, 2023). En matemáticas, un LLM estándar puede fallar en operaciones aritméticas complejas o en la demostración de teoremas debido a su incapacidad inherente para ejecutar razonamiento lógico formal paso a paso sin la integración de módulos de cálculo externos como Wolfram Alpha (Wolfram, 2023). En química, se han documentado casos donde la IA inventa rutas sintéticas termodinámicamente imposibles o asigna propiedades erróneas a biomoléculas. Esto genera un riesgo de “desclasificación del logro”, donde el estudiante confunde la obtención de una respuesta rápida con la comprensión real del proceso cognitivo (Selwyn, 2019).

DESARROLLO

El análisis crítico de la literatura científica revela una brecha sustancial entre los discursos promocionales de la eficiencia tecnológica y las evidencias empíricas recolectadas en las aulas de educación superior. Los hallazgos se estructuran en tres dimensiones críticas: la precisión técnica del dominio científico, el impacto cognitivo en los estudiantes y la tensión regulatoria-institucional.

Hallazgos de Precisión Técnica en Matemáticas y Química

Estudios empíricos con metodologías explícitas de evaluación de LLMs (como GPT-4 y Claude 3) demuestran que, si bien estas herramientas muestran un rendimiento sobresaliente en tareas de recuperación de información conceptual y redacción de textos biológicos explicativos, su precisión disminuye drásticamente al enfrentarse a problemas matemáticos no estructurados y a la resolución de problemas químicos complejos (Ahmad et al., 2024).

Disciplina	Tarea Evaluada	Tasa de Precisión Promedio (LLM Estándar)	Tipo de Error Prevalente	Fuente Referencial
Matemáticas	Modelación matemática de crecimiento poblacional (Ecuaciones Diferenciales).	62%	Errores en la secuenciación lógica del despeje y cálculo aritmético básico.	(Zhai et al., 2023)
Química	Predicción de mecanismos de reacción orgánica y estequiometría de soluciones.	54%	Alucinación de intermediarios de reacción; balanceo de ecuaciones incorrecto.	(Gao et al., 2023)

Los datos verificables demuestran que las herramientas operan de forma óptima únicamente cuando se les acopla con sistemas de computación simbólica (plugins de cálculo). Sin esta integración, el estudiante de biología recibe respuestas con una sintaxis impecable y formatos matemáticos en LaTeX formalmente atractivos, pero matemáticamente erróneos. Las limitaciones reconocidas por los propios autores de dichos estudios enfatizan que los LLMs son “lingüísticamente competentes, pero computacionalmente ciegos” (Mahowald et al., 2024).

Impacto en la Arquitectura Cognitiva del Estudiante

Desde la perspectiva de la Teoría de la Carga Cognitiva, las investigaciones que monitorearon el comportamiento de estudiantes universitarios interactuando con chatbots para resolver tareas de bioquímica demostraron un fenómeno de atrofia del andamiaje. Los estudiantes con un menor nivel de conocimientos previos en química tendieron a aceptar las respuestas de la IA de manera acrítica (sesgo de automatización).

Los resultados observados indican que el supuesto de “eficiencia” (ahorro de tiempo en la resolución de tareas) se correlaciona de forma negativa con el rendimiento en exámenes presenciales donde no se permite el uso de la tecnología (Baidoo-Anu & Ansah, 2023). El estudiante delega la carga germana (el esfuerzo mental de procesar el balanceo de una ecuación redox o la derivada de una función de tasa de mutación) a la máquina. Por lo tanto, el proceso de internalización del conocimiento se ve truncado, transformando el aprendizaje en un ejercicio superficial de transferencia de texto mediante copy-paste.

Metas Oficiales versus Resultados Observados y Marcos Regulatorios

Las agendas técnicas de organismos como la UNESCO (2023) y las metas oficiales de innovación digital de múltiples universidades de América Latina y Europa promueven la integración de la IA para alcanzar el Objetivo de Desarrollo Sostenible 4 (Educación de Calidad), asumiendo que la tecnología cerrará las brechas de aprendizaje. No obstante, las evaluaciones de política educativa evidencian una contradicción estructural:

1. Vacío Regulatorio: Los marcos normativos institucionales se han centrado casi exclusivamente en la prohibición del plagio y la integridad académica, omitiendo directrices pedagógicas sobre la validación epistemológica de los contenidos generados por IA (UNESCO, 2023).
2. Brecha de Equidad: Las versiones gratuitas y accesibles de los modelos de IA (los más utilizados por la población estudiantil general) presentan tasas de error significativamente mayores en ciencias exactas que los modelos de pago avanzados. Esto genera una nueva estratificación socio-cognitiva dentro de la misma comunidad universitaria (Williamson, 2024).

CONCLUSIONES

- Insuficiencia Epistémica de la IAGen Pura: La Inteligencia Artificial Generativa, en su estado actual basado puramente en modelos probabilísticos de lenguaje, es estructuralmente deficiente para fungir como tutor autónomo en disciplinas que exigen rigor formal deductivo como las matemáticas y la química para estudiantes de ciencias biológicas.
- Saturación Cognitiva Oculta: Aunque las herramientas reducen la ansiedad inicial y simulan eficiencia operativa, incrementan de manera invisible la carga cognitiva extrínseca de los estudiantes, quienes carecen del criterio experto necesario para auditar y corregir las alucinaciones de la IA.

- Necesidad de un Rediseño Curricular e Institucional: Las universidades no pueden depender de la autorregulación del estudiante. Se requiere el desarrollo urgente de una “alfabetización en IA” que capacite a los alumnos de biología no solo a usar la herramienta, sino a interactuar de manera crítica y escéptica con ella. La integración de la IA debe transitar hacia arquitecturas híbridas (LLMs combinados con motores de conocimiento simbólico y verificado) bajo la supervisión docente estricta, transformando el rol de la IA de un “proveedor de respuestas” a un “espejo de contrastación conceptual”.

REFERENCIAS

- Ahmad, S., Siau, K., & Keng, L. (2024). Generative artificial intelligence in STEM education: A systematic review of opportunities and precision challenges. *Journal of Educational Computing Research*, 62(2), 145–168.
- Alkaissi, H., & McFarlane, S. I. (2023). Artificial hallucinations in ChatGPT: Implications in scientific writing and medical education. *Cureus*, 15(2), e35179. <https://doi.org/10.7759/cureus.35179>
- Association for Medical Education. (2021). Developments in biological sciences and quantitative reasoning in higher education (Technical Report No. 14). Agency for Higher Education Assessment.
- Baidoo-Anu, D., & Ansah, L. O. (2023). Education in the era of generative artificial intelligence (AI): In-depth review of potential benefits and limitations of ChatGPT. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4361234>
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the 2021 ACM FAccT Conference*, 610–623.
- Cooper, M. M., Grove, N., Underwood, S., & Klymkowsky, M. W. (2010). Lost in Lewis structures: An investigation of student difficulties in conceptualizing molecular structure. *Journal of Chemical Education*, 87(8), 869–874.
- Dowker, A., Sarkar, A., & Looi, C. Y. (2016). Mathematics anxiety: What have we learned in 60 years? *Frontiers in Psychology*, 7, 508.
- Gao, C., Lin, Z., & Taylor, M. (2023). Evaluating LLMs on organic chemistry and stoichiometry: A comparative study of GPT models. *Chemical Education Research and Practice*, 24(4), 1102–1115.
- Johnstone, A. H. (1991). Why is science difficult to learn? Things are seldom what they seem. *Journal of Computer Assisted Learning*, 7(2), 75–83.
- Kirschner, P. A., Sweller, J., & Clark, R. E. (2006). Why minimal guidance during instruction does not work: An analysis of the failure of constructivist, discovery, problem-based, experiential, and inquiry-based teaching. *Educational Psychologist*, 41(2), 75–86.
- Mahowald, K., Ivanova, A. A., Blank, I. A., Kanwisher, N., Tenenbaum, J. B., & Fedorenko, E. (2024). Dissociating language and thought in large language models. *Trends in Cognitive Sciences*, 28(2), 124–140.
- Miao, F., Holmes, W., & Ronghuai, H. (2023). Guidance for generative AI in education and research. UNESCO Publishing.

- National Research Council. (2003). BIO2010: Transforming undergraduate education for future research biologists. The National Academies Press.
- Selwyn, N. (2019). Should robots replace teachers? AI and the future of education. Polity Press.
- Sweller, J. (1988). Cognitive load during problem solving: Effects on learning. *Cognitive Science*, 12(2), 257–285.
- Sweller, J., Ayres, P., & Kalyuga, S. (2011). Cognitive load theory. Springer Science & Business Media.
- UNESCO. (2023). Marcos de competencias en IA para estudiantes y docentes: Evaluaciones de política global. Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.
- Williamson, B. (2024). The digital governance of higher education: Edtech platforms, data infrastructures, and generative AI. *European Journal of Education*, 59(1), 12–26.
- Wolfram, S. (2023). What is ChatGPT doing... and why does it work? Wolfram Media, Inc.
- Zhai, X., Chu, X., Chai, C. S., Jong, M. S. Y., Istenic, A., Spector, M., Liu, J. B., Yuan, J., & Li, Y. (2023). ChatGPT for higher education: A critical analysis of its capabilities in solving mathematical and scientific problems. *Computers and Education: Artificial Intelligence*, 5, 100166.

ISBN: 978-607-5893-97-6



Sello editorial: Red Iberoamericana de Academias de Investigación,
A.C. (978-607-5893)

Primera Edición, Xalapa, Veracruz, México.

No. de ejemplares: 2

Presentación en medio electrónico digital

Formato PDF 5 MB

Fecha de aparición 04/09/2026

ISBN 978-607-5893-97-6