

SSTSDS-Vol.4. N1. 098

**Inteligencia artificial y modelos matemáticos en la resolución de
problemas complejos**

Artificial intelligence and mathematical models in complex problem solving

Autores:

Wilmer Javier Labre Tarco
Universidad Técnica de Ambato
Ambato – Ecuador
w_javo@hotmail.com
<https://orcid.org/0000-0003-2336-9380>

Stalin Gabriel Salguero Gualpa
Universidad Técnica de Cotopaxi
Latacunga – Ecuador
stalin.salguero4088@utc.edu.ec
<https://orcid.org/0009-0000-3473-6575>

Freddy Alexander Chilinguina Quispe
Unidad Educativa Ramona Auxiliadora Marcillo Chica
Santo Domingo – Ecuador
chilinguinaquispefreddy@gmail.com
<https://orcid.org/0009-0003-7120-3884>

María Eugenia Heredia Espinosa
Universidad Técnica de Cotopaxi
Latacunga – Ecuador
eugenitaheredia75@gmail.com
<https://orcid.org/0000-0001-8454-9719>

Shirley Johanna Cañar Ruiz
Investigadora independiente
Ambato – Ecuador
shirley_975@hotmail.es
<https://orcid.org/0009-0002-1697-2990>

Autor de correspondencia: Wilmer Javier Labre Tarco, w_javo@hotmail.com

Enviado: 09-05-2026
Aceptado: 02-08-2026

Revisado: 18-06-2026
Publicado: 04-08-2026



Cómo citar este artículo:

Labre Tarco, W. J., Salguero Gualpa, S. G., Chilikuinga Quispe, F. A., Heredia Espinosa, M. E., & Cañar Ruiz, S. J. (2026). Inteligencia artificial y modelos matemáticos en la resolución de problemas complejos. *Sage Sphere of Technology, Sciences, Discoveries And Society*, 4(1), 1-26. <https://doi.org/10.63688/zzaywf45>

© 2026; Los autores. Este es un artículo en acceso abierto, distribuido bajo los términos de una licencia Creative Commons (<https://creativecommons.org/licenses/by/4.0>) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea correctamente citada.



ABSTRACT

Artificial intelligence and mathematical models have become relevant tools for complex problem solving because of their capacity to process large volumes of data, identify patterns, make predictions, and optimize processes. This study aimed to analyze the contribution of artificial intelligence and mathematical models to complex problem solving. An integrative literature review was conducted through a systematic search process based on the identification, screening, eligibility, and inclusion stages established by PRISMA 2020. Fifteen publications released between 2020 and 2026 were included, comprising experimental studies, systematic reviews, integrative reviews, technical reports, and conceptual articles. The findings were organized into categories related to mathematical reasoning, language models, modeling, prediction, optimization, neuro-symbolic systems, mathematics education, verification, reliability, and human supervision. The results showed that artificial intelligence can support procedure generation, pattern identification, scenario simulation, personalized learning, and decision-making. However, its effectiveness varied according to data quality, model type, problem complexity, and the validation mechanisms applied. Limitations related to reasoning errors, inaccurate responses, lack of contextualization, algorithmic bias, limited interpretability, and excessive dependence on automated systems were also identified. It is concluded that artificial intelligence and mathematical models can strengthen complex problem solving when they are integrated critically, ethically, and systematically as a complement to human reasoning and specialized supervision.

Keywords: artificial intelligence; mathematical models; complex problem solving; mathematical reasoning; optimization.

RESUMEN

La inteligencia artificial y los modelos matemáticos se han convertido en herramientas relevantes para la resolución de problemas complejos debido a su capacidad para procesar grandes volúmenes de datos, identificar patrones, realizar predicciones y optimizar procesos. El objetivo de este estudio fue analizar la contribución de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos. Se realizó una revisión integrativa de la literatura mediante un proceso de búsqueda sistemática basado en las etapas de identificación, cribado, elegibilidad e inclusión establecidas por PRISMA 2020. Se incluyeron 15 publicaciones difundidas entre 2020 y 2026, entre estudios experimentales, revisiones sistemáticas, revisiones integrativas, informes técnicos y artículos conceptuales. Los hallazgos se organizaron en categorías relacionadas con razonamiento matemático, modelos de lenguaje, modelación, predicción, optimización, sistemas neuro-simbólicos, educación matemática, verificación, confiabilidad y supervisión humana. Los resultados mostraron que la inteligencia artificial puede apoyar la generación de procedimientos, la identificación de patrones, la simulación de escenarios, la personalización del aprendizaje y la toma de decisiones. Sin embargo, su efectividad varió según la calidad de los datos, el tipo de modelo, la complejidad del problema y los mecanismos de validación empleados. También se identificaron limitaciones relacionadas con errores de razonamiento, respuestas inexactas, falta de contextualización, sesgo algorítmico, baja interpretabilidad y dependencia excesiva de sistemas automatizados. Se concluye que la inteligencia artificial y los modelos matemáticos pueden fortalecer la resolución de problemas complejos cuando se integran de manera crítica, ética y sistemática, como complemento del razonamiento humano y la supervisión especializada.

Palabras clave: inteligencia artificial; modelos matemáticos; resolución de problemas complejos; razonamiento matemático; optimización.



1. INTRODUCCIÓN

La inteligencia artificial (IA) y los modelos matemáticos han adquirido un papel fundamental en la resolución de problemas complejos debido a su capacidad para analizar grandes volúmenes de datos, identificar patrones y optimizar procesos de decisión. El desarrollo de algoritmos de aprendizaje automático, aprendizaje profundo y modelos de lenguaje ha permitido abordar problemas científicos, industriales, financieros y de ingeniería con mayor precisión y eficiencia que los métodos tradicionales. Estas tecnologías favorecen la automatización de tareas, la simulación de escenarios y la generación de soluciones en contextos caracterizados por incertidumbre y alta complejidad (Davis, 2023; Hu & Qu, 2020).

En este contexto, los modelos matemáticos constituyen una herramienta esencial para representar fenómenos reales mediante ecuaciones, funciones y algoritmos que facilitan el análisis y la predicción de resultados. Sin embargo, muchos problemas actuales presentan características como no linealidad, múltiples variables y grandes volúmenes de información, lo que limita la efectividad de los métodos convencionales. La incorporación de técnicas de inteligencia artificial permite fortalecer estos modelos mediante procesos de aprendizaje, optimización y adaptación continua, mejorando la capacidad para resolver problemas complejos en diferentes áreas del conocimiento (Su et al., 2026; Eti et al., 2026; Sarıkaya & Kuzu, 2026).

Las investigaciones recientes evidencian que la integración entre inteligencia artificial y modelos matemáticos contribuye significativamente al razonamiento matemático, la optimización y el descubrimiento científico. Los modelos de lenguaje de gran escala (LLMs), los sistemas neuro-simbólicos y los métodos de verificación formal han demostrado un potencial creciente para apoyar la resolución de problemas matemáticos avanzados y la generación de nuevas soluciones. No obstante, diversos estudios también señalan limitaciones relacionadas con la interpretabilidad de los modelos, la confiabilidad de las respuestas, la dependencia de datos de calidad y la necesidad de mecanismos de validación para garantizar resultados precisos y verificables (Ju & Dong, 2026; Raiyan et al., 2026; “Solutions, Challenges,” 2026).



A pesar de los importantes avances alcanzados, la literatura científica continúa mostrando diferencias en cuanto a la efectividad de los modelos de inteligencia artificial según el algoritmo empleado, el dominio de aplicación y las estrategias de modelado utilizadas. Asimismo, persisten desafíos relacionados con la transparencia, la ética, la explicabilidad y la integración del conocimiento matemático con técnicas de inteligencia artificial, aspectos que requieren mayor investigación para garantizar un uso responsable y eficiente de estas tecnologías (Barkeshli et al., 2026; Cao et al., 2026).

Por lo tanto, resulta necesario analizar de manera integral la contribución de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos, identificando sus principales aplicaciones, beneficios y desafíos reportados por la literatura científica reciente. En este sentido, el presente estudio tiene como objetivo analizar la contribución de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos, respondiendo a la siguiente pregunta de investigación: ¿Cómo contribuyen la inteligencia artificial y los modelos matemáticos a la resolución de problemas complejos en los diferentes campos de aplicación reportados por la literatura científica reciente?

2. MARCO TEÓRICO

Inteligencia artificial

La inteligencia artificial (IA) es un área de la informática orientada al desarrollo de sistemas capaces de realizar tareas que requieren procesos cognitivos similares a los humanos, como el aprendizaje, el razonamiento, la toma de decisiones y la resolución de problemas. En los últimos años, el avance del aprendizaje profundo, los modelos de lenguaje de gran escala y las técnicas de aprendizaje automático ha incrementado significativamente la capacidad de estos sistemas para analizar grandes volúmenes de datos y generar soluciones en diferentes contextos científicos e industriales. La IA ha evolucionado desde aplicaciones especializadas hacia herramientas con capacidades de razonamiento más complejas, permitiendo apoyar actividades de investigación, optimización y modelado matemático.

Modelos matemáticos

Los modelos matemáticos representan fenómenos reales mediante ecuaciones, funciones, algoritmos y relaciones cuantitativas que permiten comprender el comportamiento de sistemas complejos. Estos modelos facilitan la simulación, predicción y optimización de



procesos en disciplinas como la ingeniería, economía, salud y ciencias ambientales. Sin embargo, el incremento de la complejidad de los problemas actuales ha impulsado la incorporación de técnicas de inteligencia artificial para mejorar la precisión de las predicciones y la eficiencia en la toma de decisiones.

Inteligencia artificial aplicada a la resolución de problemas complejos

Diversas investigaciones recientes destacan que la inteligencia artificial fortalece los modelos matemáticos mediante algoritmos capaces de identificar patrones, procesar información no estructurada y generar soluciones adaptativas. En particular, los modelos de lenguaje, el aprendizaje profundo y los sistemas neuro-simbólicos han demostrado avances importantes en el razonamiento matemático, la optimización y el descubrimiento científico.

En esta línea, Trinh et al. (2024) desarrollaron *AlphaGeometry*, un sistema de inteligencia artificial capaz de resolver problemas de geometría de nivel olímpico mediante la integración de modelos de lenguaje con razonamiento simbólico. Los resultados evidenciaron que la combinación entre inteligencia artificial y métodos matemáticos mejora significativamente la capacidad para resolver problemas complejos; sin embargo, los autores señalan que estos sistemas aún requieren supervisión humana para validar la exactitud y coherencia de las soluciones propuestas.

Estas herramientas permiten abordar problemas caracterizados por incertidumbre, múltiples variables y grandes volúmenes de datos, superando limitaciones de los métodos tradicionales.

Aplicaciones de la inteligencia artificial y los modelos matemáticos

La integración de la IA con los modelos matemáticos ha generado aplicaciones relevantes en sectores como la medicina, la ingeniería, la logística, la industria y la educación. En el ámbito educativo, la IA favorece el desarrollo de habilidades para la resolución de problemas matemáticos mediante sistemas personalizados de aprendizaje. En ingeniería e industria, permite optimizar procesos productivos y mejorar la planificación mediante algoritmos predictivos. Asimismo, en investigación científica facilita el descubrimiento de nuevas relaciones matemáticas y la automatización parcial de demostraciones y procesos de verificación.

Desafíos y perspectivas

A pesar de los avances alcanzados, la literatura reciente señala que persisten desafíos relacionados con la interpretabilidad de los modelos, la confiabilidad de las



respuestas generadas, la calidad de los datos utilizados para el entrenamiento y las implicaciones éticas derivadas del uso de la inteligencia artificial.

De igual manera, el informe técnico presentado por OpenAI (2023) señala que los modelos de lenguaje de gran escala poseen un importante potencial para apoyar el razonamiento matemático, la programación y la resolución de problemas complejos. No obstante, también reconoce limitaciones relacionadas con las denominadas *alucinaciones*, los errores de razonamiento y la necesidad de implementar mecanismos de verificación humana que garanticen la confiabilidad y precisión de las respuestas generadas.

Asimismo, diversos estudios indican que los modelos actuales aún presentan dificultades para resolver problemas matemáticos contextualizados y para justificar completamente sus procesos de razonamiento, por lo que continúa siendo indispensable la supervisión humana y la validación matemática de los resultados obtenidos. Estas limitaciones representan oportunidades para futuras investigaciones orientadas al desarrollo de sistemas más transparentes, robustos y explicables.

3. METODOLOGÍA

Diseño de la investigación

El presente estudio se desarrolló mediante una revisión integrativa de la literatura con búsqueda sistemática, orientada a analizar la contribución de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos. Este diseño permitió reunir estudios experimentales, investigaciones aplicadas, revisiones sistemáticas, informes técnicos y artículos conceptuales.

Se aplicó un enfoque cualitativo, descriptivo y analítico. Según Lubbe et al. (2020), la revisión integrativa permite comparar y sintetizar diferentes tipos de evidencia para identificar tendencias, aportes, limitaciones y vacíos de conocimiento.

Las publicaciones se dividieron en fuentes primarias y secundarias. Las fuentes primarias incluyeron estudios experimentales, investigaciones aplicadas e informes técnicos; mientras que las secundarias comprendieron revisiones sistemáticas, revisiones de literatura y artículos conceptuales.

Fuentes de información y estrategia de búsqueda



La búsqueda bibliográfica se realizó en Scopus, Web of Science, ScienceDirect, SpringerLink, Taylor & Francis Online, SAGE Journals, SciELO, Redalyc, Google Scholar y arXiv.

Se emplearon términos en español e inglés relacionados con inteligencia artificial, modelos matemáticos, razonamiento y resolución de problemas, combinados mediante los operadores booleanos AND y OR.

La ecuación general de búsqueda fue:

(“artificial intelligence” OR “machine learning” OR “large language models” OR “inteligencia artificial”) AND (“mathematical models” OR “mathematical reasoning” OR “modelos matemáticos”) AND (“complex problem solving” OR “optimization” OR “resolución de problemas complejos”)

También se utilizaron combinaciones complementarias como:

(“artificial intelligence” AND “mathematical problem solving”)

(“large language models” AND “mathematical reasoning”)

(“neuro-symbolic systems” AND “mathematics”)

(“artificial intelligence” AND “mathematics education”)

Las ecuaciones fueron adaptadas a las características de cada plataforma. Los resultados se organizaron en una matriz de Microsoft Excel que contenía autor, año, título, tipo de documento, objetivo, metodología, técnica de inteligencia artificial, modelo matemático, principales resultados, limitaciones y DOI.

Los registros duplicados fueron identificados mediante la comparación de los autores, el título, el año de publicación y el DOI.

Criterios de elegibilidad

Criterios de inclusión

Se incluyeron las publicaciones que cumplieron con las siguientes condiciones:

- Publicadas entre 2020 y 2026.
- Relacionadas con inteligencia artificial, modelos matemáticos o resolución de problemas complejos.
- Correspondientes a estudios experimentales, revisiones sistemáticas, informes técnicos o artículos científicos.



- Publicadas en español o inglés.
- Con texto completo disponible.
- Con información bibliográfica verificable.
- Con objetivos, metodología, resultados y conclusiones claramente descritos.

Criterios de exclusión

Se excluyeron:

- Registros duplicados.
- Artículos de opinión, blogs o documentos sin respaldo académico.
- Publicaciones fuera del periodo establecido.
- Estudios sin acceso al texto completo.
- Documentos sin información bibliográfica verificable.
- Investigaciones sin relación directa con el tema.
- Publicaciones que no describían suficientemente su metodología o resultados.

Proceso de selección de los estudios

La selección se realizó siguiendo las etapas de identificación, cribado, elegibilidad e inclusión establecidas en la declaración PRISMA 2020. Page et al. (2021) señalan que este procedimiento permite presentar de forma transparente cómo se localizaron, evaluaron, excluyeron e incluyeron las publicaciones.

Inicialmente se identificaron 86 registros en las bases de datos y plataformas consultadas. Después de eliminar 21 registros duplicados, quedaron 65 publicaciones para la revisión de títulos y resúmenes.

Durante el cribado se excluyeron 35 registros por no relacionarse directamente con la inteligencia artificial, los modelos matemáticos o la resolución de problemas complejos. De esta manera, se seleccionaron 30 documentos para su recuperación y evaluación a texto completo.

Los 30 documentos fueron recuperados y revisados. Durante la etapa de elegibilidad se excluyeron 15 publicaciones:

- Seis no presentaban una relación directa con el tema.
- Cuatro no describían suficientemente la metodología.
- Tres eran documentos conceptuales demasiado generales.




- Dos no proporcionaban información suficiente sobre los modelos o algoritmos utilizados.

Finalmente, se incluyeron 15 publicaciones en la revisión integrativa.

Figura 1

Diagrama de flujo PRISMA 2020 del proceso de selección de los estudios



Nota. El proceso de selección siguió las etapas de identificación, eliminación de duplicados, cribado, recuperación, elegibilidad e inclusión establecidas por PRISMA 2020. Se identificaron 86 registros, se eliminaron 21 duplicados y se examinaron 65 títulos y resúmenes. Después de excluir 35 registros, se evaluaron 30 documentos a texto completo. Finalmente, se excluyeron 15 publicaciones y se incluyeron 15 estudios en la revisión.

Tabla 1

Resumen del proceso PRISMA



Etapa	Cantidad
Registros identificados	86
Registros duplicados eliminados	21
Registros examinados mediante título y resumen	65
Registros excluidos durante el cribado	35
Textos completos recuperados	30
Documentos evaluados para elegibilidad	30
Documentos excluidos después de la lectura completa	15
Estudios incluidos en la revisión	15

Nota. Extracción y análisis de la información. Elaboración propia.

La información se organizó mediante una matriz que incluyó las siguientes variables:

- Autor y año.
- Tipo de publicación.
- Objetivo.
- Diseño metodológico.
- Campo de aplicación.
- Técnica de inteligencia artificial.
- Modelo o razonamiento matemático.
- Principales resultados.
- Limitaciones.
- Aporte general.
- DOI o identificador bibliográfico.

Cada publicación fue comparada con su texto completo. Cuando se identificó información incompleta o contradictoria, el documento se revisó nuevamente antes de incorporarlo a la matriz.

El análisis se realizó mediante categorización temática, siguiendo a Braun y Clarke (2021).

Los hallazgos se organizaron en las siguientes categorías:

- Modelos de lenguaje y razonamiento matemático.
- Inteligencia artificial aplicada a la resolución de problemas.



- Aprendizaje automático y modelación matemática.
- Sistemas neuro-simbólicos y verificación formal.
- Inteligencia artificial en educación matemática.
- Personalización del aprendizaje.
- Exactitud, contextualización e interpretabilidad.
- Supervisión humana, ética y confiabilidad.

No se realizó un metaanálisis estadístico debido a las diferencias entre los diseños, algoritmos, variables, contextos y procedimientos de evaluación. Por esta razón, la evidencia fue sintetizada de forma descriptiva y temática.

Evaluación de la calidad metodológica

La calidad metodológica se evaluó mediante ocho criterios:

- C1: claridad de los objetivos.
- C2: adecuación del fundamento teórico.
- C3: transparencia metodológica.
- C4: pertinencia del diseño.
- C5: descripción de la muestra, corpus o evidencia.
- C6: claridad del análisis.
- C7: correspondencia entre resultados y conclusiones.
- C8: reconocimiento de las limitaciones.

Cada criterio se calificó de la siguiente manera:

- 0: no se cumple.
- 1: se cumple parcialmente.
- 2: se cumple completamente.

La puntuación máxima fue de 16 puntos. Las publicaciones con 80 % o más fueron clasificadas como de calidad alta; entre 60 % y 79 %, como de calidad moderada; y con menos del 60 %, como de calidad baja.

Tabla 2

Resultados de la evaluación de la calidad metodológica



N.º	Autor y año	Tipo de documento	C1	C2	C3	C4	C5	C6	C7	C8	Total	Porcentaje	Calidad
1	Cao et al. (2026)	Artículo científico	2	2	2	2	2	2	2	1	15/16	93,75 %	Alta
2	Daher y Gierdien (2024)	Estudio aplicado	2	2	2	2	2	2	2	1	15/16	93,75 %	Alta
3	Eti et al. (2026)	Revisión sistemática	2	2	2	2	2	2	2	2	16/16	100 %	Alta
4	Feng et al. (2026)	Artículo científico	2	2	1	2	2	2	2	1	14/16	87,50 %	Alta
5	Frieder et al. (2023)	Estudio experimental	2	2	2	2	2	2	2	2	16/16	100 %	Alta
6	Hu y Qu (2020)	Revisión conceptual	2	2	1	1	1	2	2	1	12/16	75 %	Moderada
7	Ju y Dong (2026)	Revisión integrativa	2	2	2	2	2	2	2	1	15/16	93,75 %	Alta
8	“Solutions, challenges” (2026)	Artículo de perspectiva	2	2	1	1	1	2	2	1	12/16	75 %	Moderada
9	OpenAI (2023)	Informe técnico	2	2	2	2	2	2	2	2	16/16	100 %	Alta
10	Panqueban y Huincahue (2024)	Revisión sistemática	2	2	2	2	2	2	2	2	16/16	100 %	Alta
11	Raiyan et al. (2026)	Revisión integrativa	2	2	2	2	2	2	2	1	15/16	93,75 %	Alta



N.º	Autor y año	Tipo de documento	C1	C2	C3	C4	C5	C6	C7	C8	Total	Porcentaje	Calidad
12	Sarıkaya y Kuzu (2026)	Artículo de revisión	2	2	2	2	2	2	2	1	15/16	93,75 %	Alta
13	Su et al. (2026)	Revisión sistemática	2	2	2	2	2	2	2	2	16/16	100 %	Alta
14	Trinh et al. (2024)	Estudio experimental	2	2	2	2	2	2	2	2	16/16	100 %	Alta
15	Zheng et al. (2024)	Revisión de literatura	2	2	2	2	2	2	2	1	15/16	93,75 %	Alta

Nota. C1 = claridad de los objetivos; C2 = adecuación del fundamento teórico; C3 = transparencia metodológica; C4 = pertinencia del diseño; C5 = descripción de la muestra, corpus o evidencia; C6 = claridad del análisis; C7 = correspondencia entre resultados y conclusiones; C8 = reconocimiento de limitaciones.

La evaluación mostró que 13 publicaciones fueron clasificadas como de calidad alta y dos como de calidad moderada. Ninguna publicación fue clasificada como de calidad baja.

Las publicaciones de Hu y Qu (2020) y “Solutions, challenges” (2026) alcanzaron calidad moderada porque sus diseños conceptuales o de perspectiva presentaron menor detalle metodológico. Estas fuentes fueron conservadas por su aporte teórico al tema.

Proceso y protocolo de revisión

La selección de las publicaciones, la evaluación del texto completo, la extracción de información y la valoración metodológica fueron realizadas por un solo revisor.

La información fue verificada mediante la comparación con las publicaciones originales. Debido a que no participó un segundo revisor, no se calculó la concordancia entre evaluadores.

La revisión no fue registrada previamente en una plataforma de protocolos. Sin embargo, se documentaron las bases de datos, las ecuaciones de búsqueda, los criterios de selección, el proceso PRISMA, las variables de extracción y los criterios de calidad para mejorar la transparencia del estudio.



4. RESULTADOS

Características generales de las publicaciones incluidas

El corpus final estuvo conformado por 15 publicaciones difundidas entre 2020 y 2026. Las fuentes incluyeron estudios experimentales, investigaciones aplicadas, revisiones sistemáticas, revisiones integrativas, revisiones de literatura, artículos conceptuales, artículos de perspectiva científica e informes técnicos.

Las publicaciones seleccionadas examinaron modelos de lenguaje de gran escala, aprendizaje automático, sistemas neuro-simbólicos, razonamiento automatizado, inteligencia artificial generativa, modelos predictivos y aplicaciones educativas. Los principales resultados estuvieron relacionados con el razonamiento matemático, la resolución de problemas, la modelación, la optimización, la predicción, la automatización, el aprendizaje personalizado y la verificación de resultados.

Debido a que los estudios presentaron diferencias en sus diseños metodológicos, modelos de inteligencia artificial, procedimientos matemáticos, campos de aplicación y métodos de evaluación, los resultados fueron sintetizados de manera descriptiva. Los hallazgos se organizaron en cuatro bloques temáticos generales:

- 1. Razonamiento matemático y resolución de problemas.
- 2. Modelación, predicción y optimización.
- 3. Educación matemática y aprendizaje personalizado.
- 4. Confiabilidad, supervisión humana y limitaciones tecnológicas.

Tabla 3

Matriz general de las fuentes incluidas en la revisión integrativa de la literatura

N.º	Estudio	Tipo de fuente	Enfoque principal	Categoría temática
1	Cao et al. (2026)	Artículo científico	Limitaciones de los modelos de lenguaje para resolver problemas matemáticos contextualizados	Razonamiento matemático; confiabilidad y contextualización



N.º	Estudio	Tipo de fuente	Enfoque principal	Categoría temática
2	Daher y Gierdien (2024)	Estudio aplicado	Uso del lenguaje generado por ChatGPT en la resolución de problemas matemáticos	Modelos de lenguaje; comunicación y razonamiento matemático
3	Eti et al. (2026)	Revisión sistemática	Aprendizaje personalizado mediante inteligencia artificial para desarrollar habilidades de resolución de problemas	Educación matemática; personalización del aprendizaje
4	Feng et al. (2026)	Artículo científico	Utilización de sistemas autónomos de inteligencia artificial en la investigación matemática	Automatización; descubrimiento matemático
5	Frieder et al. (2023)	Estudio experimental	Evaluación de las capacidades matemáticas de ChatGPT	Razonamiento matemático; precisión y errores
6	Hu y Qu (2020)	Revisión conceptual	Restricciones generalizadas como problema matemático de la inteligencia artificial	Modelación matemática; fundamentos de la inteligencia artificial
7	Ju y Dong (2026)	Revisión integrativa	Progresos, desafíos y perspectivas de la inteligencia artificial aplicada a las matemáticas	Razonamiento matemático; avances y desafíos
8	“Solutions, challenges” (2026)	Artículo de perspectiva	Soluciones y tensiones emergentes entre inteligencia artificial y matemáticas	Confiabilidad; limitaciones científicas y tecnológicas



N.º	Estudio	Tipo de fuente	Enfoque principal	Categoría temática
9	OpenAI (2023)	Informe técnico	Capacidades y limitaciones de GPT-4 en razonamiento, programación y resolución de problemas	Modelos de lenguaje; errores y verificación humana
10	Panqueban y Huincahue (2024)	Revisión sistemática	Aplicaciones de inteligencia artificial en educación matemática	Enseñanza y aprendizaje de las matemáticas
11	Raiyan et al. (2026)	Revisión integrativa	Integración de modelos de lenguaje, sistemas neuro-simbólicos y métodos de verificación	Sistemas neuro-simbólicos; verificación formal
12	Sarikaya y Kuzu (2026)	Artículo de revisión	Evolución de la inteligencia artificial en la resolución de problemas matemáticos	Educación matemática; evolución tecnológica
13	Su et al. (2026)	Revisión sistemática	Uso de ChatGPT para fortalecer la enseñanza y el aprendizaje de las matemáticas	Personalización; apoyo educativo
14	Trinh et al. (2024)	Estudio experimental	Desarrollo de AlphaGeometry para resolver problemas geométricos de nivel olímpico	Geometría; razonamiento neuro-simbólico
15	Zheng et al. (2024)	Revisión de literatura	Aplicaciones de modelos de lenguaje de gran escala en contextos educativos	Educación; beneficios y limitaciones de la inteligencia artificial

Nota. El corpus final estuvo compuesto por 15 publicaciones relacionadas directamente con la inteligencia artificial, los modelos matemáticos y la resolución de problemas complejos. Las fuentes incluyeron estudios experimentales, revisiones sistemáticas, revisiones integrativas, informes técnicos y artículos conceptuales. Una misma publicación podía



pertenecer a más de una categoría temática cuando analizaba varias aplicaciones, resultados o limitaciones.

Razonamiento matemático y resolución de problemas

La evidencia revisada mostró que la inteligencia artificial puede ampliar las posibilidades de resolución de problemas matemáticos mediante la generación de procedimientos, la identificación de patrones y la propuesta de posibles soluciones. Los modelos de lenguaje de gran escala demostraron capacidad para resolver determinados ejercicios, explicar conceptos y generar secuencias de razonamiento.

Sin embargo, el rendimiento de estas herramientas no fue uniforme. Los resultados dependieron de la complejidad del problema, la claridad de las instrucciones, la cantidad de pasos requeridos y la capacidad del modelo para mantener la coherencia lógica.

Frieder et al. (2023) analizaron las capacidades matemáticas de ChatGPT e identificaron que podía resolver algunos problemas correctamente, pero también cometía errores en cálculos, demostraciones y procedimientos de varios pasos. De manera similar, OpenAI (2023) reconoció que los modelos de lenguaje pueden producir respuestas aparentemente convincentes que contienen errores de razonamiento o información incorrecta.

En general, estas herramientas resultaron más útiles como apoyo para explorar soluciones, generar explicaciones y comparar procedimientos que como sistemas completamente autónomos. Los resultados deben ser revisados, especialmente cuando se aplican a problemas avanzados o contextualizados.

Modelación, predicción y optimización

Las publicaciones indicaron que la inteligencia artificial puede fortalecer los modelos matemáticos mediante algoritmos capaces de procesar grandes volúmenes de datos, reconocer relaciones y ajustar predicciones.

El aprendizaje automático y el aprendizaje profundo permiten analizar problemas caracterizados por incertidumbre, múltiples variables, relaciones no lineales y cambios continuos. Estas capacidades favorecen la simulación de escenarios, la optimización de recursos y la toma de decisiones.

Hu y Qu (2020) destacaron la importancia de incorporar restricciones matemáticas dentro de los sistemas de inteligencia artificial. Estas restricciones ayudan a evitar soluciones



incompatibles con las condiciones del problema y mejoran la coherencia de los resultados. La inteligencia artificial y los modelos matemáticos funcionan de manera complementaria. Los modelos matemáticos proporcionan estructura, ecuaciones y restricciones, mientras que la inteligencia artificial aporta capacidad de aprendizaje, adaptación y procesamiento de información compleja.

No obstante, la precisión de los resultados depende de la calidad de los datos, la selección del algoritmo y la correcta formulación del problema. Los datos incompletos, sesgados o poco representativos pueden generar predicciones incorrectas.

Educación matemática y aprendizaje personalizado

La inteligencia artificial también presentó aplicaciones relevantes en la enseñanza y el aprendizaje de las matemáticas. Las herramientas inteligentes pueden generar ejercicios, adaptar actividades, ofrecer explicaciones y proporcionar retroalimentación según las necesidades del estudiante.

Panqueban y Huincahue (2024) identificaron aplicaciones relacionadas con tutorías inteligentes, evaluación automatizada, personalización y apoyo durante la resolución de problemas. Estas tecnologías permiten que los estudiantes practiquen a su propio ritmo y reciban orientación inmediata.

Eti et al. (2026) señalaron que el aprendizaje personalizado mediante inteligencia artificial puede contribuir al desarrollo de habilidades para resolver problemas. Sin embargo, los beneficios dependen de la calidad de las actividades, la confiabilidad de las respuestas y la orientación docente.

Su et al. (2026) analizaron el uso de ChatGPT como recurso para fortalecer la enseñanza y el aprendizaje de las matemáticas. Entre sus aplicaciones se encuentran la generación de ejemplos, la explicación de procedimientos y la elaboración de ejercicios.

A pesar de estas ventajas, existe el riesgo de que los estudiantes acepten respuestas incorrectas o dependan excesivamente de la herramienta. Por esta razón, la inteligencia artificial debe utilizarse para estimular el razonamiento, la comparación y la verificación, y no únicamente para proporcionar respuestas finales.

Confiabilidad, supervisión humana y limitaciones tecnológicas



La confiabilidad fue uno de los principales desafíos identificados. Los modelos de inteligencia artificial pueden generar errores de cálculo, procedimientos incompletos o información falsa presentada de manera convincente.

Cao et al. (2026) señalaron que los modelos de lenguaje todavía presentan dificultades para resolver problemas matemáticos contextualizados. Un sistema puede responder correctamente a una formulación abstracta, pero fallar cuando necesita interpretar condiciones implícitas o información relacionada con una situación real.

Los sistemas neuro-simbólicos representan una alternativa para mejorar esta confiabilidad. Trinh et al. (2024) desarrollaron AlphaGeometry mediante la combinación de modelos de lenguaje y razonamiento simbólico. El sistema mostró que integrar aprendizaje automático con reglas matemáticas puede mejorar el desempeño en problemas estructurados.

Raiyan et al. (2026) también destacaron que los mecanismos de verificación formal pueden comprobar si una solución cumple las reglas y restricciones matemáticas establecidas.

Las principales limitaciones identificadas fueron:

- Errores de cálculo y razonamiento.
- Respuestas inventadas o alucinaciones.
- Dificultades para comprender problemas contextualizados.
- Dependencia de la calidad de los datos.
- Falta de transparencia de algunos algoritmos.
- Sesgos en los datos de entrenamiento.
- Dificultades para justificar completamente los procedimientos.
- Necesidad de supervisión y verificación humana.

En general, los hallazgos muestran que la inteligencia artificial y los modelos matemáticos pueden ampliar las capacidades de análisis, predicción, optimización y resolución de problemas. Sin embargo, sus resultados dependen del tipo de problema, la calidad de los datos, la estructura matemática incorporada y la existencia de mecanismos de validación.

5. DISCUSIÓN

La presente revisión integrativa analizó la contribución de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos. Los resultados muestran que ambas herramientas pueden mejorar el análisis, la predicción, la simulación, la optimización



y la toma de decisiones. Sin embargo, su efectividad depende de la calidad de los datos, el diseño de los modelos y la verificación de los resultados.

Razonamiento matemático y resolución de problemas

La inteligencia artificial puede apoyar el razonamiento matemático mediante la generación de procedimientos, la identificación de patrones y la propuesta de soluciones. Los modelos de lenguaje han demostrado capacidad para resolver algunos ejercicios y explicar conceptos, aunque también pueden cometer errores en cálculos y problemas de varios pasos.

Frieder et al. (2023) identificaron fortalezas y limitaciones en las capacidades matemáticas de ChatGPT, mientras que OpenAI (2023) reconoció que estos modelos pueden producir respuestas convincentes, pero incorrectas. Por ello, la inteligencia artificial debe emplearse como apoyo al razonamiento humano y no como sustituto de la validación matemática.

Modelación, predicción y optimización

La inteligencia artificial puede fortalecer los modelos matemáticos al procesar grandes volúmenes de datos, detectar relaciones y ajustar predicciones. Esta capacidad resulta útil en problemas con incertidumbre, múltiples variables y comportamientos no lineales.

Los modelos matemáticos aportan estructura y restricciones, mientras que la inteligencia artificial proporciona aprendizaje y adaptación. Hu y Qu (2020) destacaron que incorporar restricciones matemáticas permite reducir soluciones incompatibles con las condiciones reales del problema. No obstante, la precisión depende de la calidad y representatividad de los datos.

Sistemas neuro-simbólicos y verificación

Los sistemas neuro-simbólicos combinan redes neuronales con reglas lógicas y procedimientos matemáticos. Trinh et al. (2024) desarrollaron AlphaGeometry, un sistema capaz de resolver problemas geométricos mediante la integración de modelos de lenguaje y razonamiento simbólico.

Raiyan et al. (2026) señalaron que la verificación formal puede mejorar la confiabilidad de las soluciones. Sin embargo, estos sistemas aún presentan dificultades para interpretar contextos nuevos y justificar completamente sus procedimientos, por lo que la supervisión humana continúa siendo necesaria.

Educación matemática y aprendizaje personalizado



La inteligencia artificial puede apoyar la enseñanza de las matemáticas mediante la generación de ejercicios, la adaptación de actividades y la retroalimentación inmediata.

Panqueban y Huincahue (2024), Eti et al. (2026) y Su et al. (2026) destacaron beneficios relacionados con tutorías inteligentes, personalización y apoyo en la resolución de problemas. Sin embargo, su uso debe estar acompañado por la orientación docente, ya que los estudiantes pueden depender excesivamente de la herramienta o aceptar respuestas incorrectas sin verificarlas.

Confiabilidad y contextualización

La confiabilidad constituye uno de los principales desafíos. Los modelos pueden generar errores, respuestas inventadas o procedimientos incompletos.

Cao et al. (2026) señalaron que los modelos de lenguaje presentan dificultades para resolver problemas contextualizados. Por ello, las respuestas deben contrastarse con datos reales, condiciones del problema y conocimientos especializados.

Supervisión humana y desafíos éticos

La inteligencia artificial puede ampliar las capacidades humanas, pero no reemplaza la responsabilidad de docentes, investigadores o especialistas. La supervisión resulta esencial para seleccionar modelos, verificar datos e interpretar los resultados.

También se identificaron desafíos relacionados con privacidad, sesgo algorítmico, falta de transparencia, acceso desigual a la tecnología y dependencia de sistemas automatizados. La incorporación de estas herramientas debe acompañarse de capacitación, protección de datos y criterios claros de uso.

Limitaciones del estudio

La selección, extracción y evaluación de las publicaciones fueron realizadas por un solo revisor. Además, la revisión no fue registrada previamente y reunió estudios con diferentes diseños, algoritmos y procedimientos de evaluación.

Esta diversidad permitió obtener una visión amplia, pero impidió realizar un metaanálisis. Las futuras investigaciones deberían comparar modelos en condiciones similares, utilizar datos transparentes y profundizar en la explicabilidad, la privacidad, los sesgos y la verificación formal.

6. CONCLUSIONES



La presente revisión integrativa analizó la contribución de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos. La evidencia indica que su integración puede fortalecer el razonamiento matemático, la modelación, la predicción, la optimización, la simulación y la toma de decisiones.

La principal contribución de la inteligencia artificial se relaciona con su capacidad para procesar grandes cantidades de datos, identificar patrones, generar posibles soluciones y adaptar sus respuestas. Por su parte, los modelos matemáticos proporcionan estructura, relaciones cuantitativas, restricciones y mecanismos de comprobación.

Los beneficios fueron más evidentes cuando ambas herramientas se utilizaron de manera complementaria. Los sistemas de inteligencia artificial resultaron más confiables cuando incorporaron reglas matemáticas, razonamiento simbólico y procedimientos de verificación. Los modelos de lenguaje mostraron capacidad para resolver algunos problemas, explicar conceptos y proponer procedimientos. Sin embargo, también presentaron errores de cálculo, respuestas inventadas, dificultades de contextualización y limitaciones para justificar completamente su razonamiento.

En educación matemática, la inteligencia artificial puede apoyar la generación de ejercicios, la retroalimentación, la explicación de procedimientos y el aprendizaje personalizado. Estas ventajas dependen de la orientación docente, la calidad de las actividades y la participación crítica del estudiante.

La evidencia no respalda el reemplazo del razonamiento humano ni de la supervisión especializada. Los resultados generados por inteligencia artificial deben ser revisados, interpretados y validados antes de utilizarse en decisiones científicas, educativas, industriales o profesionales.

La confiabilidad de estas tecnologías depende de la calidad de los datos, la selección del modelo, las restricciones incorporadas, la transparencia del procedimiento y la existencia de mecanismos de verificación. También deben considerarse aspectos éticos relacionados con privacidad, sesgo, acceso desigual y responsabilidad.

Las conclusiones de la revisión están condicionadas por la diversidad metodológica de las 15 publicaciones, la inclusión de fuentes primarias y secundarias, la participación de un solo revisor y la ausencia de un protocolo registrado previamente.



Las futuras investigaciones deberían evaluar modelos en problemas reales y contextualizados, comparar sistemas bajo condiciones similares y desarrollar métodos más transparentes, explicables y verificables. También resulta necesario estudiar el impacto de la inteligencia artificial en diferentes áreas y establecer normas para su uso responsable.

En conclusión, la inteligencia artificial y los modelos matemáticos constituyen herramientas complementarias con un importante potencial para resolver problemas complejos. Su incorporación debe realizarse de forma crítica, planificada y supervisada, de manera que fortalezca el análisis humano sin sustituir la responsabilidad, la interpretación especializada y la validación matemática.

REFERENCIAS BIBLIOGRÁFICAS

- Barkeshli, M., Douglas, M. R., & Freedman, M. H. (2026). *Artificial intelligence and the structure of mathematics* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2604.06107>
- Braun, V., & Clarke, V. (2021). One size fits all? What counts as quality practice in reflexive thematic analysis? *Qualitative Research in Psychology*, 18(3), 328–352. <https://doi.org/10.1080/14780887.2020.1769238>
- Cao, B., Zhang, D., Li, Y., Liu, J., Huang, S., Shi, C., Lu, H., Wu, Y., Chen, G., Lam, W., & Wei, F. (2026). *From abstract to contextual: What LLMs still cannot do in mathematics* [Conference paper]. International Conference on Learning Representations. <https://openreview.net/forum?id=KBknLdXxTa>
- Daher, W., & Gierdien, F. (2024). Use of language by generative AI tools in mathematical problem solving: The case of ChatGPT. *African Journal of Research in Mathematics, Science and Technology Education*, 28(2), 222–235. <https://doi.org/10.1080/18117295.2024.2384676>
- Davis, E. (2023). *Mathematics, word problems, common sense, and artificial intelligence* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2301.09723>
- Eti, N., Mosia, M. M., & Egara, F. O. (2026). The role of AI-driven personalised learning in enhancing mathematics problem-solving skills: A systematic review. *Frontiers in Computer Science*, 8, Article 1813431. <https://doi.org/10.3389/fcomp.2026.1813431>



- Feng, T., Trinh, T. H., Bingham, G., Hwang, D., Chervonyi, Y., Jung, J., Lee, J., Pagano, C., Kim, S., Pasqualotto, F., Gukov, S., Lee, J. N., Kim, J., Hou, K., Ghiasi, G., Tay, Y., Li, Y., Kuang, C., Liu, Y., ... Luong, T. (2026). *Towards autonomous mathematics research* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2602.10177>
- Frieder, S., Pinchetti, L., Chevalier, A., Griffiths, R. R., Salvatori, T., Lukasiewicz, T., Petersen, P. C., & Berner, J. (2023). *Mathematical capabilities of ChatGPT* [Preprint]. arXiv. <https://arxiv.org/abs/2301.13867>
- Hu, B. G., & Qu, H. B. (2020). *Generalized constraints as a new mathematical problem in artificial intelligence: A review and perspective* [Preprint]. arXiv. <https://arxiv.org/abs/2011.06156>
- Ju, H., & Dong, B. (2026). *AI for mathematics: Progress, challenges, and prospects* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2601.13209>
- Lubbe, W., Ham-Baloyi, W., & Smit, K. (2020). The integrative literature review as a research method: A demonstration review of research on neurodevelopmental supportive care in preterm infants. *Journal of Neonatal Nursing*, 26(6), 308–315. <https://doi.org/10.1016/j.jnn.2020.04.006>
- OpenAI. (2023). *GPT-4 technical report* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2303.08774>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, Article n71. <https://doi.org/10.1136/bmj.n71>
- Panqueban, D., & Huincahue, J. (2024). Artificial intelligence in mathematics education: A systematic review. *Uniciencia*, 38(1). <https://doi.org/10.15359/ru.38-1.20>
- Raiyan, S. R., Kabir, M., Mahmud, H., & Hasan, M. K. (2026). *Artificial intelligence for mathematical reasoning: An integrated survey of language models, neuro-symbolic systems, and verified discovery* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2606.08728>



Sarıkaya, K., & Kuzu, Ç. İ. (2026). The evolution of artificial intelligence in mathematical problem-solving processes: A mathematics education perspective. *SAGE Open*, 16(1). <https://doi.org/10.1177/21582440261426456>

Solutions, challenges and rising tensions in AI and mathematics. (2026). *Nature Machine Intelligence*, 8, 857. <https://doi.org/10.1038/s42256-026-01269-x>

Su, C. S., Hsu, C. C., & González Campos, J. A. (2026). ChatGPT as a resource to strengthen mathematics teaching and learning: A systematic review. *Journal of Computer Assisted Learning*, 42(3), Article e70241. <https://doi.org/10.1002/jcal.70241>

Trinh, T. H., Wu, Y., Le, Q. V., He, H., & Luong, T. (2024). Solving olympiad geometry without human demonstrations. *Nature*, 625(7995), 476–482. <https://doi.org/10.1038/s41586-023-06747-5>

Zheng, Y., Qin, H., Ma, X., & Wang, Y. (2024). Large language models in education: A comprehensive review. *Computers & Education*, 210, Article 104885. <https://doi.org/10.1016/j.compedu.2024.104885>

CONFLICTO DE INTERESES

No existe.

FINANCIAMIENTO

No aplica

CONTRIBUCIÓN DE AUTORÍA (CRediT)

Conceptualización: Wilmer Javier Labre Tarco, Stalin Gabriel Salguero Gualpa, Freddy Alexander Chiliquinga Quispe, María Eugenia Heredia Espinosa y Shirley Johanna Cañar Ruiz.

Metodología: Wilmer Javier Labre Tarco, Stalin Gabriel Salguero Gualpa, Freddy Alexander Chiliquinga Quispe, María Eugenia Heredia Espinosa y Shirley Johanna Cañar Ruiz.

Investigación: Wilmer Javier Labre Tarco, Stalin Gabriel Salguero Gualpa, Freddy Alexander Chiliquinga Quispe, María Eugenia Heredia Espinosa y Shirley Johanna Cañar Ruiz.

Redacción – borrador original: Wilmer Javier Labre Tarco, Stalin Gabriel Salguero Gualpa, Freddy Alexander Chiliquinga Quispe, María Eugenia Heredia Espinosa y Shirley Johanna Cañar Ruiz.

Redacción – revisión y edición: Wilmer Javier Labre Tarco, Stalin Gabriel Salguero Gualpa, Freddy Alexander Chiliquinga Quispe, María Eugenia Heredia Espinosa y Shirley Johanna Cañar Ruiz.

