

SSTSDS-Vol.4. N1. 165

Integración de la inteligencia artificial y los modelos matemáticos para la resolución de problemas complejos: una revisión bibliográfica

Integration of artificial intelligence and mathematical models for solving complex problems: a literature review

Autores:

Edwin Xavier Escobar Guanoluisa
Unidad Educativa Luis Fernando Ruiz, Latacunga, Ecuador
xavierescobar1980@gmail.com
<https://orcid.org/0009-0004-4112-5368>

Roberth Damián Guamani Guamani
Unidad Educativa Municipal del Milenio Bicentenario, Quito, Ecuador
guamaniroberth@hotmail.com
<https://orcid.org/0009-0007-1604-5149>

Alex Fernando León Chancusig
Unidad Educativa Luis Fernando Ruiz, Latacunga, Ecuador
alexchancusig532@gmail.com
<https://orcid.org/0009-0009-9305-2988>

Gladys Marisol Rodríguez Vallejo
Investigadora independiente, Quito, Ecuador
maryrodriguezuce@gmail.com
<https://orcid.org/0009-0007-3559-3458>

María José Peñaranda Loor
Unidad Educativa Fiscal 24 de Mayo, Quito, Ecuador
majopl0707@gmail.com
<https://orcid.org/0009-0002-5818-3914>

Autor de correspondencia: Edwin Xavier Escobar Guanoluisa, xavierescobar1980@gmail.com

Enviado: 25-08-2026
Aceptado: 25-10-2026

Revisado: 06-10-2026
Publicado: 26-10-2026

Cómo citar este artículo:

Escobar Guanoluisa, E. X., Guamani Guamani, R. D., León Chancusig, A. F., Rodríguez Vallejo, G. M., & Peñaranda Loor, M. J. (2026). Integración de la inteligencia artificial y los modelos matemáticos para la resolución de problemas complejos: una revisión bibliográfica. *Sage Sphere of Technology, Sciences, Discoveries And Society*, 4(1), 1-25. <https://doi.org/10.63688/95dv3370>

© 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

This study aimed to analyze the integration of artificial intelligence and mathematical models in solving complex problems across scientific and technological disciplines. A structured literature review with a qualitative and descriptive-analytical approach was conducted, considering 15 scientific publications from 2019 to 2023. The documentary analysis was organized into five thematic categories: integration of artificial intelligence and mathematical foundations, algorithmic optimization and computational simulation, prediction of dynamic systems and natural phenomena, applications in scientific discovery, and interpretability of intelligent models. The reviewed studies examined approaches such as physics-informed neural networks, neural operators, machine learning, deep reinforcement learning, numerical simulation, and computational prediction. The findings identified opportunities to approximate solutions to differential equations, optimize mathematical algorithms, improve computational simulations, predict dynamic phenomena, and support scientific discovery. However, differences in computational architectures, mathematical formulations, evaluation metrics, and application contexts prevented the establishment of consistent quantitative effects across the studies. It was concluded that integrating artificial intelligence with mathematical models provides valuable opportunities for solving complex problems when supported by rigorous mathematical formulation, reliable data, computational validation, and appropriate interpretation of results. Further research is recommended to compare intelligent algorithms with conventional mathematical methods and evaluate their accuracy, computational efficiency, generalizability, and interpretability.

Keywords: artificial intelligence; mathematical models; complex problem-solving; machine learning; computational optimization.

RESUMEN

La presente investigación tuvo como objetivo analizar la integración de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos en diferentes disciplinas científicas y tecnológicas. Se desarrolló una revisión bibliográfica estructurada, con enfoque cualitativo y alcance descriptivo-analítico, considerando 15 publicaciones científicas correspondientes al período 2019–2023. El análisis documental se organizó en cinco categorías temáticas: integración de inteligencia artificial y fundamentos matemáticos, optimización algorítmica y simulación computacional, predicción de sistemas dinámicos y fenómenos naturales, aplicaciones en descubrimiento científico e interpretabilidad de modelos inteligentes. Se examinaron enfoques como redes neuronales informadas por principios físicos, operadores neuronales, aprendizaje automático, aprendizaje por refuerzo profundo, simulación numérica y predicción computacional. Los resultados identificaron oportunidades para aproximar soluciones de ecuaciones diferenciales, optimizar algoritmos matemáticos, mejorar simulaciones computacionales, predecir fenómenos dinámicos y contribuir al descubrimiento científico. Sin embargo, las diferencias entre arquitecturas computacionales, formulaciones matemáticas, métricas de evaluación y contextos de aplicación impidieron establecer efectos cuantitativos uniformes entre las investigaciones. Se concluyó que la integración de inteligencia artificial y modelos matemáticos constituye una alternativa relevante para abordar problemas complejos, siempre que se acompañe de formulaciones matemáticas rigurosas, información confiable, validación computacional e interpretación adecuada de los resultados. Se recomienda desarrollar investigaciones que comparen algoritmos inteligentes con métodos matemáticos convencionales y evalúen su precisión, eficiencia computacional, capacidad de generalización e interpretabilidad.

Palabras clave: inteligencia artificial; modelos matemáticos; resolución de problemas complejos; aprendizaje automático; optimización computacional.



1. INTRODUCCIÓN

La creciente complejidad de los problemas científicos, tecnológicos y sociales ha impulsado el desarrollo de herramientas capaces de analizar grandes volúmenes de información, interpretar fenómenos dinámicos y optimizar procesos de decisión. En este contexto, la inteligencia artificial y los modelos matemáticos constituyen recursos importantes para abordar sistemas caracterizados por múltiples variables, relaciones no lineales e incertidumbre. Brunton et al. (2020) destacaron las aplicaciones del aprendizaje automático en la mecánica de fluidos, mientras que Karniadakis et al. (2021) y Willard et al. (2023) examinaron la integración de principios físicos y matemáticos con algoritmos inteligentes para mejorar la representación y el análisis de fenómenos científicos.

Los métodos matemáticos convencionales presentan desafíos al aplicarse a sistemas de elevada dimensionalidad y procesos que requieren grandes recursos computacionales. Frente a estas limitaciones, la inteligencia artificial ofrece alternativas para complementar la simulación, predicción y optimización. Raissi et al. (2019) desarrollaron redes neuronales informadas por principios físicos para resolver problemas directos e inversos mediante ecuaciones diferenciales. Asimismo, Li et al. (2021) propusieron un operador neuronal de Fourier para aproximar soluciones de ecuaciones diferenciales parciales, mientras que Cuomo et al. (2022) identificaron avances y dificultades relacionadas con el entrenamiento, la convergencia y la precisión de estos modelos.

En el ámbito de la optimización computacional, la integración de algoritmos inteligentes y formulaciones matemáticas ha permitido desarrollar procedimientos más eficientes. Kochkov et al. (2021) investigaron la aceleración de simulaciones de dinámica de fluidos mediante aprendizaje automático. Por su parte, Fawzi et al. (2022) emplearon aprendizaje por refuerzo para descubrir algoritmos eficientes de multiplicación matricial, mientras que Degraeve et al. (2022) aplicaron esta técnica al control magnético de plasmas en dispositivos experimentales de fusión. Estas investigaciones evidencian posibilidades para abordar problemas caracterizados por múltiples restricciones matemáticas y físicas.

En las ciencias naturales, el aprendizaje profundo ha favorecido el desarrollo de modelos para analizar y predecir fenómenos complejos. Reichstein et al. (2019) destacaron la importancia de combinar datos observacionales y conocimientos científicos para comprender



procesos del sistema terrestre. Asimismo, Bi et al. (2023) desarrollaron un sistema de predicción meteorológica basado en redes neuronales tridimensionales, mientras que Lam et al. (2023) presentaron un modelo de pronóstico global con resultados competitivos en precisión y eficiencia computacional. Estos avances muestran las posibilidades de complementar los métodos tradicionales de predicción mediante herramientas inteligentes. La inteligencia artificial también ha contribuido al descubrimiento científico. Jumper et al. (2021) desarrollaron un sistema de aprendizaje profundo para predecir estructuras tridimensionales de proteínas, mientras que Merchant et al. (2023) aplicaron modelos computacionales para identificar estructuras cristalinas candidatas. Estas aplicaciones evidencian la utilidad de integrar algoritmos inteligentes y representaciones matemáticas para explorar relaciones complejas en biología y ciencia de materiales.

No obstante, la implementación de estos modelos plantea desafíos relacionados con la calidad de los datos, la precisión, los requerimientos computacionales y la interpretabilidad de los resultados. Rudin (2019) destacó la importancia de utilizar modelos interpretables en decisiones de alto impacto, mientras que Karniadakis et al. (2021) y Cuomo et al. (2022) señalaron la necesidad de incorporar fundamentos científicos y mejorar los procedimientos de entrenamiento y validación. En consecuencia, la utilidad de la inteligencia artificial depende de una adecuada formulación matemática, la selección de algoritmos y la evaluación rigurosa de sus resultados.

Por ello, el presente artículo tiene como objetivo analizar la integración de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos, mediante una revisión de publicaciones científicas correspondientes al período 2019–2023, considerando sus principales aplicaciones, beneficios, limitaciones y posibilidades de implementación en diferentes áreas del conocimiento.

2. METODOLOGÍA

a) Enfoque del estudio

Se realizó una revisión bibliográfica estructurada, con enfoque cualitativo y alcance descriptivo-analítico, sobre la integración de la inteligencia artificial y los modelos matemáticos en la resolución de problemas complejos. El corpus comprendió 15



publicaciones científicas del período 2019–2023. El análisis fue documental, narrativo y comparativo, sin experimentos computacionales propios ni metaanálisis.

b) Método

Se caracterizaron las publicaciones mediante sus objetivos, métodos, algoritmos, formulaciones matemáticas, resultados y limitaciones, distinguiendo investigaciones computacionales o experimentales, desarrollos algorítmicos, revisiones científicas y análisis conceptuales. Se siguieron criterios explícitos de inclusión y exclusión y se consideraron los principios de transparencia metodológica de Page et al. (2021), sin atribuir al trabajo el carácter de revisión sistemática completa conforme a PRISMA 2020.

c) Estrategia de búsqueda bibliográfica

La revisión documental se realizó el 6 de junio de 2026 y se centró en publicaciones de 2019–2023. Para su organización temática se consideraron descriptores en español e inglés relacionados con inteligencia artificial, aprendizaje automático, modelos matemáticos, ecuaciones diferenciales, optimización, simulación computacional y predicción de sistemas dinámicos (Tabla 1).

No se conservan historiales suficientes para verificar las bases de datos consultadas, las ecuaciones de búsqueda ejecutadas ni las cantidades de registros identificados, duplicados o excluidos. Por ello, los descriptores de la Tabla 1 tienen una función temática y no constituyen ecuaciones de búsqueda comprobadas. Esta limitación reduce la reproducibilidad de la revisión.

Tabla 1.

Descriptores temáticos considerados en la organización documental

Categoría temática	Descriptores en español	Descriptores en inglés
Inteligencia artificial	Inteligencia artificial; aprendizaje automático	Artificial intelligence; machine learning
Modelos matemáticos	Modelado matemático; modelos matemáticos	Mathematical modeling; mathematical models
Ecuaciones diferenciales	Ecuaciones diferenciales; redes neuronales informadas por la física	Differential equations; physics-informed neural networks
Optimización	Optimización matemática; aprendizaje por refuerzo	Mathematical optimization; reinforcement learning



Simulación computacional	Simulación numérica; dinámica de fluidos computacional	Numerical simulation; computational fluid dynamics
Predicción de sistemas	Predicción; sistemas dinámicos; aprendizaje profundo	Prediction; dynamic systems; deep learning
Problemas complejos	Problemas complejos; sistemas no lineales	Complex problems; nonlinear systems

Nota. Los descriptores se organizaron en español e inglés para caracterizar las publicaciones científicas incluidas en la revisión. Su función es temática y clasificatoria; no representan necesariamente ecuaciones de búsqueda ejecutadas en bases de datos académicas específicas.

d) Identificación de los registros

De las publicaciones examinadas se registraron, cuando estuvieron disponibles, autoría, año, título, fuente académica, DOI o enlace permanente y datos sobre sus métodos y resultados. Dada la falta de trazabilidad de la recuperación inicial, se informa únicamente el corpus final de 15 publicaciones, sin reconstruir recuentos de registros previos.

e) Selección y evaluación de los estudios

La selección se basó en la revisión de títulos, resúmenes, palabras clave y contenidos disponibles, atendiendo a la pertinencia temática, claridad metodológica y contribución científica. Los documentos se organizaron en matrices de caracterización para su análisis comparativo.

Se aplicaron seis criterios: claridad del objetivo (C1), coherencia entre objetivo y metodología (C2), descripción del problema científico o matemático (C3), identificación de algoritmos y procedimientos computacionales (C4), correspondencia entre resultados y conclusiones (C5) y pertinencia temática (C6). Estos criterios fueron descriptivos; no se asignaron puntuaciones de calidad ni se realizó una evaluación formal del riesgo de sesgo.

Criterios de inclusión

- Artículos científicos, investigaciones computacionales, revisiones académicas y análisis conceptuales publicados entre 2019 y 2023.
- Publicaciones en español o inglés con DOI o enlace académico permanente y verificable.
- Estudios relacionados con inteligencia artificial, modelos matemáticos y resolución de problemas complejos.



- Investigaciones sobre aprendizaje automático, ecuaciones diferenciales, optimización, simulación o predicción, con aportes teóricos, metodológicos o científicos pertinentes.

Criterios de exclusión

- Registros duplicados o publicaciones fuera del período 2019–2023.
- Documentos sin respaldo académico identificable.
- Investigaciones sin relación suficiente con inteligencia artificial y modelación matemática.
- Trabajos con información metodológica insuficiente o sin contribuciones pertinentes al objetivo de investigación.

f) Fuentes y muestra documental

El corpus documental abordó redes neuronales informadas por la física, operadores neuronales, optimización, simulación de fluidos, predicción meteorológica, estructuras moleculares y descubrimiento de materiales. La Tabla 2 presenta las publicaciones según su área de aplicación y tipo de investigación, mientras que la Tabla 3 compara sus enfoques metodológicos.

Tabla 2.

Caracterización de las 15 publicaciones científicas según área de aplicación y tipo de investigación

N.º	Autor(es) y año	Área de aplicación	Tipo de investigación
1	Brunton et al. (2020)	Mecánica de fluidos	Revisión científica
2	Karniadakis et al. (2021)	Aprendizaje informado por la física	Revisión científica
3	Willard et al. (2023)	Ingeniería y ciencias ambientales	Revisión científica
4	Raissi et al. (2019)	Ecuaciones diferenciales parciales	Investigación computacional
5	Li et al. (2021)	Operadores neuronales y ecuaciones diferenciales	Desarrollo algorítmico
6	Cuomo et al. (2022)	Aprendizaje automático científico	Revisión científica
7	Kochkov et al. (2021)	Dinámica de fluidos computacional	Investigación computacional
8	Fawzi et al. (2022)	Optimización de operaciones matriciales	Investigación algorítmica



9	Degrave et al. (2022)	Control de plasmas	Investigación experimental y computacional
10	Reichstein et al. (2019)	Ciencias del sistema terrestre	Revisión científica
11	Bi et al. (2023)	Predicción meteorológica	Investigación computacional
12	Lam et al. (2023)	Predicción meteorológica	Investigación computacional
13	Jumper et al. (2021)	Estructuras de proteínas	Investigación computacional
14	Merchant et al. (2023)	Ciencia de materiales	Investigación computacional
15	Rudin (2019)	Interpretabilidad de modelos	Análisis conceptual y metodológico

Nota. Se presentan las 15 publicaciones científicas seleccionadas, organizadas según su área de aplicación y tipo de investigación. Esta clasificación permite reconocer la diversidad disciplinaria y metodológica del corpus documental, sin establecer equivalencias entre investigaciones experimentales, computacionales, documentales y conceptuales.

Tabla 3.

Comparación de enfoques metodológicos de las publicaciones seleccionadas

Enfoque metodológico	Procedimientos empleados	Aspectos analizados
Aprendizaje informado por principios físicos	Redes neuronales informadas por la física, operadores neuronales y modelos híbridos	Aproximación de soluciones de ecuaciones diferenciales, incorporación de restricciones físicas y problemas de convergencia
Optimización algorítmica y simulación	Aprendizaje automático, aprendizaje por refuerzo y simulación numérica	Eficiencia de algoritmos, aceleración computacional y control de sistemas dinámicos
Predicción de fenómenos naturales	Aprendizaje profundo, redes neuronales tridimensionales y modelos predictivos	Precisión meteorológica, representación de procesos ambientales y eficiencia computacional
Descubrimiento científico	Modelos de aprendizaje profundo y predicción computacional	Estructuras proteicas, exploración de materiales y validación científica
Interpretabilidad de modelos	Análisis conceptual de modelos interpretables y sistemas de caja negra	Transparencia, comprensión de decisiones algorítmicas y confiabilidad

Nota. Elaboración propia a partir de las publicaciones seleccionadas. Se comparan los procedimientos y aspectos analizados por enfoque, con finalidad descriptiva y sin establecer puntuaciones de calidad metodológica.



g) Procedimiento de análisis de datos

Se realizó una síntesis narrativa y comparativa de objetivos, métodos, algoritmos, formulaciones matemáticas, resultados y limitaciones. Cada una de las 15 publicaciones se asignó a una categoría principal, según su contribución predominante: integración de inteligencia artificial y fundamentos matemáticos (5), optimización algorítmica y simulación computacional (4), predicción de sistemas dinámicos y fenómenos naturales (3), descubrimiento científico (2) e interpretabilidad de modelos inteligentes (1). Esta organización distingue tipos de evidencia y no implica una evaluación formal de calidad ni una comparación cuantitativa homogénea.

3. RESULTADOS

La revisión bibliográfica de las 15 publicaciones científicas correspondientes al período 2019–2023 permitió organizar los aportes identificados en cinco categorías temáticas: integración de inteligencia artificial y fundamentos matemáticos (5 estudios), optimización algorítmica y simulación computacional (4 estudios), predicción de sistemas dinámicos y fenómenos naturales (3 estudios), aplicaciones en descubrimiento científico (2 estudios) e interpretabilidad de modelos inteligentes (1 estudio).

Se establecieron 15 asignaciones temáticas, correspondientes a las 15 publicaciones seleccionadas. Cada investigación se incorporó en una categoría principal de acuerdo con su contribución predominante, aunque algunas abordaron aspectos relacionados con otras categorías. Esta clasificación permitió organizar los diferentes enfoques científicos sin incrementar artificialmente el número de documentos analizados.

La organización temática evidenció la diversidad de aplicaciones de la inteligencia artificial en problemas matemáticos y científicos. Las investigaciones relacionadas con ecuaciones diferenciales y aprendizaje informado por la física se concentraron en la construcción y evaluación de modelos computacionales, mientras que los estudios sobre optimización y predicción examinaron procedimientos para mejorar algoritmos, representar sistemas dinámicos y generar pronósticos. Por su parte, las aplicaciones en ciencias naturales y la investigación sobre interpretabilidad aportaron elementos para analizar el alcance y las limitaciones de estas herramientas.

Síntesis comparativa según el tipo de evidencia científica

Para interpretar los resultados se diferenciaron las investigaciones computacionales y experimentales de las publicaciones de revisión científica y análisis conceptual. Los estudios computacionales aportaron resultados relacionados con el desarrollo, entrenamiento y evaluación de algoritmos aplicados a problemas específicos. Las investigaciones experimentales permitieron examinar el comportamiento de sistemas inteligentes en condiciones físicas determinadas, mientras que las revisiones científicas integraron conocimientos, enfoques metodológicos y limitaciones identificadas en investigaciones anteriores.

Esta diferenciación permitió evitar que los aportes de revisiones documentales fueran presentados como resultados de experimentos realizados directamente por sus autores. Asimismo, se consideró que las mejoras obtenidas en determinados problemas matemáticos o científicos no pueden generalizarse automáticamente a todos los sistemas complejos, debido a las diferencias en sus variables, condiciones de evaluación y procedimientos computacionales.

Tabla 4.

Comparación de resultados científicos según el tipo de evidencia

Tipo de evidencia	Publicaciones	Principales aportes y alcance
Investigaciones computacionales y desarrollos algorítmicos	Raissi et al. (2019), Li et al. (2021), Kochkov et al. (2021), Fawzi et al. (2022), Bi et al. (2023), Lam et al. (2023), Jumper et al. (2021) y Merchant et al. (2023)	Desarrollo y evaluación de algoritmos, simulaciones, predicciones y soluciones matemáticas en condiciones específicas
Investigación experimental y computacional	Degrave et al. (2022)	Aplicación de aprendizaje por refuerzo al control físico de plasmas, mediante evaluación computacional y experimentación
Revisiones científicas	Brunton et al. (2020), Karniadakis et al. (2021), Willard et al. (2023), Cuomo et al. (2022) y Reichstein et al. (2019)	Integración y análisis de conocimientos, avances y limitaciones de investigaciones anteriores



Análisis conceptual y
metodológico

Rudin (2019)

Fundamentación sobre
interpretabilidad, transparencia y
comprensión de modelos
inteligentes

Nota. La tabla compara las 15 publicaciones científicas según la naturaleza predominante de su evidencia. Se agrupan las investigaciones computacionales y los desarrollos algorítmicos, diferenciándolos de la investigación que integra experimentación física y evaluación computacional, de las revisiones científicas y del análisis conceptual. Esta clasificación permite interpretar los aportes de cada estudio considerando su diseño metodológico y evita atribuir resultados experimentales a investigaciones exclusivamente computacionales.

Integración de inteligencia artificial y fundamentos matemáticos

La integración de inteligencia artificial y fundamentos matemáticos constituyó una de las categorías centrales de las publicaciones examinadas. Raissi et al. (2019) desarrollaron redes neuronales informadas por principios físicos para resolver problemas directos e inversos formulados mediante ecuaciones diferenciales parciales. Este enfoque permitió incorporar restricciones derivadas de las ecuaciones gobernantes durante el entrenamiento de modelos computacionales. Por su parte, Li et al. (2021) propusieron un operador neuronal de Fourier para aprender relaciones entre funciones y aproximar soluciones de familias de ecuaciones diferenciales paramétricas, identificando posibilidades de acelerar determinados procedimientos numéricos.

Karniadakis et al. (2021) examinaron la integración de principios físicos y matemáticos en sistemas de aprendizaje automático, destacando las oportunidades que ofrece el conocimiento científico para orientar el desarrollo de modelos inteligentes. De manera complementaria, Willard et al. (2023) analizaron estrategias destinadas a combinar modelos basados en principios científicos con técnicas de aprendizaje automático. Asimismo, Cuomo et al. (2022) identificaron avances y dificultades de las redes neuronales informadas por la física, especialmente en aspectos relacionados con el entrenamiento, la convergencia y la precisión de las aproximaciones.

En conjunto, estas publicaciones permiten reconocer que la incorporación de formulaciones matemáticas en algoritmos inteligentes representa una alternativa para abordar problemas cuya resolución mediante procedimientos convencionales puede resultar



computacionalmente exigente. No obstante, los resultados dependen de la naturaleza de las ecuaciones, las condiciones iniciales y de frontera, la arquitectura computacional y los procedimientos de validación empleados.

Optimización algorítmica y simulación computacional

La optimización algorítmica y la simulación computacional constituyeron aplicaciones relevantes de la inteligencia artificial en la resolución de problemas complejos. Las investigaciones examinadas permitieron identificar mejoras específicas en el rendimiento de determinados procedimientos matemáticos y computacionales, especialmente en simulación de fluidos y optimización de operaciones matriciales.

Brunton et al. (2020) examinaron diversas aplicaciones del aprendizaje automático en mecánica de fluidos, destacando sus posibilidades para complementar los métodos tradicionales de modelación, simulación y control. Por su parte, Kochkov et al. (2021) desarrollaron un enfoque de aprendizaje profundo integrado en procedimientos de dinámica de fluidos computacional para simular flujos turbulentos bidimensionales. Los autores reportaron resultados de precisión comparables con los de simuladores convencionales que utilizaban una resolución espacial entre 8 y 10 veces mayor en cada dimensión, alcanzando aceleraciones computacionales de entre 40 y 80 veces en los escenarios evaluados. Asimismo, identificaron estabilidad durante simulaciones prolongadas y capacidad de generalización a determinadas condiciones no incluidas en el entrenamiento.

Estos resultados evidencian que la incorporación de modelos de aprendizaje automático en procedimientos numéricos puede contribuir a reducir los requerimientos computacionales sin comprometer necesariamente la precisión de las simulaciones. Sin embargo, las mejoras reportadas corresponden a configuraciones específicas de turbulencia bidimensional y no deben extrapolarse automáticamente a otros problemas físicos o sistemas de mayor complejidad.

En relación con la optimización matemática, Fawzi et al. (2022) desarrollaron AlphaTensor, un sistema basado en aprendizaje por refuerzo profundo para descubrir algoritmos eficientes de multiplicación matricial. En operaciones con matrices de 4×4 sobre el campo binario ($\mathbb{Z}_2$), identificaron un algoritmo que requiere 47 multiplicaciones escalares, frente a las 49 del algoritmo de Strassen de dos niveles. Por otra parte, en aritmética convencional, encontraron un procedimiento para multiplicar matrices de 4×5 por matrices de 5



× 5 que utiliza 76 multiplicaciones, frente a las 80 del mejor algoritmo previamente conocido. Estos resultados corresponden a configuraciones matemáticas diferentes y deben interpretarse según el tipo de aritmética empleado.

Estos hallazgos demuestran que el aprendizaje por refuerzo puede contribuir al descubrimiento de nuevos algoritmos matemáticos y a la reducción del número de operaciones necesarias para resolver determinados problemas. No obstante, una disminución de multiplicaciones escalares no implica necesariamente una reducción proporcional del tiempo de ejecución, debido a la influencia de la arquitectura computacional, la implementación algorítmica y las características del hardware utilizado.

De manera complementaria, Degraeve et al. (2022) aplicaron aprendizaje por refuerzo profundo al control magnético de plasmas en dispositivos experimentales de fusión, evidenciando posibilidades de utilizar algoritmos inteligentes en sistemas físicos caracterizados por múltiples variables y restricciones.

En conjunto, las investigaciones analizadas muestran que la inteligencia artificial puede complementar los procedimientos matemáticos convencionales mediante la aceleración de simulaciones, el descubrimiento de algoritmos y la optimización de operaciones específicas. Sin embargo, la magnitud de las mejoras depende del tipo de problema, las condiciones de evaluación, los métodos de comparación y los recursos computacionales disponibles. Por consiguiente, los resultados deben interpretarse en sus respectivos contextos experimentales y computacionales.

Predicción de sistemas dinámicos y fenómenos naturales

La predicción de sistemas dinámicos y fenómenos naturales constituyó una de las aplicaciones relevantes de la inteligencia artificial identificadas en las publicaciones científicas examinadas. Las investigaciones analizadas evidenciaron avances en el desarrollo de modelos computacionales capaces de representar relaciones atmosféricas complejas, procesar grandes volúmenes de información y generar pronósticos meteorológicos con niveles competitivos de precisión y eficiencia computacional.

Reichstein et al. (2019) examinaron las aplicaciones del aprendizaje profundo en las ciencias del sistema terrestre, destacando la importancia de integrar datos observacionales, conocimientos científicos y procedimientos matemáticos para mejorar la comprensión de los fenómenos ambientales. Este enfoque permitió reconocer la importancia de



combinar información espacial, temporal y física en los modelos de predicción de sistemas naturales.

Por su parte, Bi et al. (2023) desarrollaron Pangu-Weather, un sistema de predicción meteorológica basado en redes neuronales tridimensionales y una arquitectura de transformadores adaptada a las características de la atmósfera terrestre. Los resultados mostraron que el sistema alcanzó un rendimiento competitivo en predicción meteorológica determinista y superó al sistema operativo Integrated Forecasting System (IFS) en las variables evaluadas frente a datos de reanálisis. Asimismo, los autores reportaron una velocidad de procesamiento más de 10.000 veces superior a la del sistema operativo IFS, evidenciando una reducción considerable de los requerimientos computacionales para generar pronósticos en las condiciones analizadas.

De manera complementaria, Lam et al. (2023) desarrollaron GraphCast, un sistema basado en aprendizaje automático para la predicción meteorológica global de mediano plazo. El modelo permitió generar pronósticos de hasta 10 días, con una resolución espacial de 0,25 grados, en un tiempo inferior a un minuto. En las evaluaciones realizadas, GraphCast superó al sistema meteorológico de referencia HRES en aproximadamente el 90 % de los 1.380 objetivos de verificación considerados, demostrando un desempeño competitivo en precisión predictiva y eficiencia computacional.

La comparación de ambos estudios permite identificar coincidencias en el empleo de modelos de aprendizaje profundo para representar procesos atmosféricos de elevada complejidad. No obstante, presentan diferencias en sus arquitecturas computacionales y procedimientos de evaluación. Mientras Bi et al. (2023) utilizaron transformadores tridimensionales adaptados a la estructura de la atmósfera, Lam et al. (2023) emplearon redes neuronales basadas en grafos para representar y predecir la evolución de variables meteorológicas.

Asimismo, las métricas reportadas no deben interpretarse como directamente equivalentes, debido a que corresponden a diferentes sistemas de referencia, condiciones computacionales y criterios de evaluación. En consecuencia, aunque ambas investigaciones evidencian avances relevantes en predicción meteorológica mediante inteligencia artificial, sus resultados requieren una interpretación contextualizada que considere la calidad de los datos,



los horizontes de predicción, la resolución espacial y los procedimientos de validación empleados.

Aplicaciones en descubrimiento científico

Las aplicaciones de inteligencia artificial en descubrimiento científico representaron otra línea de investigación identificada. Jumper et al. (2021) desarrollaron un sistema de aprendizaje profundo para predecir estructuras tridimensionales de proteínas, alcanzando resultados destacados de precisión en evaluaciones de estructura proteica. Esta investigación evidenció las posibilidades de utilizar algoritmos computacionales para abordar problemas científicos caracterizados por numerosas relaciones estructurales.

De manera complementaria, Merchant et al. (2023) investigaron la utilización de aprendizaje profundo en el descubrimiento de materiales, identificando estructuras cristalinas candidatas mediante procedimientos computacionales de predicción y evaluación. Estos resultados evidencian oportunidades para explorar espacios de búsqueda extensos y orientar nuevas investigaciones científicas.

Aunque estas aplicaciones corresponden a disciplinas diferentes, ambas utilizan representaciones matemáticas y procedimientos de aprendizaje automático para analizar relaciones complejas. Sin embargo, la identificación computacional de estructuras candidatas no sustituye necesariamente la validación experimental de sus propiedades o condiciones de aplicación.

Interpretabilidad de los modelos inteligentes

La interpretabilidad constituyó una categoría transversal relevante para comprender las limitaciones de la inteligencia artificial aplicada a problemas complejos. Rudin (2019) examinó las dificultades asociadas con la utilización de modelos de aprendizaje automático poco interpretables en decisiones de alto impacto y defendió la importancia de desarrollar modelos cuyos procedimientos puedan comprenderse directamente.

Este aporte permite reconocer que la precisión predictiva no constituye el único criterio para evaluar la utilidad de un sistema inteligente. También deben considerarse la transparencia del modelo, la coherencia de sus resultados, la posibilidad de detectar errores y la interpretación de las relaciones matemáticas que sustentan las decisiones.



En consecuencia, la implementación de inteligencia artificial en problemas científicos y tecnológicos requiere procedimientos de evaluación que permitan examinar tanto el desempeño computacional como la confiabilidad e interpretabilidad de los resultados.

Tabla 5.

Síntesis de hallazgos y limitaciones por categorías de análisis

Categoría de análisis	N.º de estudios	Principales hallazgos	Limitaciones identificadas
Integración de inteligencia artificial y fundamentos matemáticos	5	Integración de principios físicos, ecuaciones diferenciales y aprendizaje automático para aproximar soluciones de problemas complejos.	Dificultades de convergencia, precisión, validación y generalización.
Optimización algorítmica y simulación computacional	4	Desarrollo de algoritmos para optimizar operaciones matemáticas, acelerar simulaciones y controlar sistemas dinámicos.	Dependencia de las condiciones experimentales y de los recursos computacionales.
Predicción de sistemas dinámicos y fenómenos naturales	3	Aplicación del aprendizaje profundo para representar procesos naturales y mejorar la predicción meteorológica.	Dependencia de la calidad de los datos, los horizontes de predicción y los criterios de evaluación.
Aplicaciones en descubrimiento científico	2	Predicción de estructuras proteicas y exploración computacional de nuevos materiales.	Necesidad de validación experimental de los resultados computacionales.
Interpretabilidad de modelos inteligentes	1	Importancia de utilizar modelos comprensibles y transparentes en decisiones de alto impacto.	Dificultades para interpretar determinados procedimientos algorítmicos.
Total	15		

Nota. Elaboración propia a partir de los 15 estudios seleccionados. Cada publicación se clasificó en una categoría principal. Las frecuencias representan cantidades de estudios y no medidas de efectividad o rendimiento computacional.

Tabla 6.

Comparación de resultados cuantitativos reportados en investigaciones seleccionadas.



Estudio	Método	Resultado reportado	Referencia de comparación
Kochkov et al. (2021)	Aprendizaje profundo integrado en simulación de fluidos	Aceleración de 40–80 veces	Simuladores numéricos con una resolución espacial 8–10 veces más fina en cada dimensión
Fawzi et al. (2022)	AlphaTensor	47 multiplicaciones frente a 49 para matrices de 4×4 sobre el campo binario (Z_2); 76 frente a 80 para multiplicar matrices de 4×5 por 5×5 en aritmética convencional.	Mejores algoritmos anteriores para los casos evaluados
Bi et al. (2023)	Pangu-Weather	Velocidad más de 10.000 veces superior	Sistema operativo IFS
Lam et al. (2023)	GraphCast	Superioridad predictiva en aproximadamente el 90 % de 1.380 objetivos; pronósticos de 10 días en menos de un minuto	Sistema operativo HRES

Nota. Elaboración propia a partir de Kochkov et al. (2021), Fawzi et al. (2022), Bi et al. (2023) y Lam et al. (2023). Los resultados corresponden a métricas y condiciones de evaluación distintas, por lo que no son directamente comparables. En Fawzi et al. (2022), las 47 multiplicaciones corresponden al campo binario (Z_2), mientras que las 76 corresponden a aritmética convencional.

Coincidencias, diferencias y limitaciones de la evidencia

El análisis comparativo de los resultados cuantitativos permitió identificar diferencias relevantes en las contribuciones de las investigaciones seleccionadas. Kochkov et al. (2021) evidenciaron mejoras de eficiencia computacional en la simulación de fluidos turbulentos, alcanzando aceleraciones de entre 40 y 80 veces respecto de los procedimientos numéricos utilizados como referencia. En contraste, Fawzi et al. (2022) abordaron un problema de optimización algorítmica y reportaron reducciones en el número de multiplicaciones escalares necesarias para determinadas operaciones matriciales, demostrando la capacidad del aprendizaje por refuerzo para descubrir procedimientos matemáticos más eficientes. Por otra parte, Bi et al. (2023) y Lam et al. (2023) examinaron aplicaciones de inteligencia artificial en predicción meteorológica. El primero reportó una aceleración computacional superior a 10.000 veces frente al sistema operativo IFS, mientras que el segundo alcanzó



mejores resultados predictivos que HRES en aproximadamente el 90 % de 1.380 objetivos de verificación, además de generar pronósticos globales de hasta 10 días en menos de un minuto.

Estas investigaciones coinciden en identificar oportunidades para mejorar determinados procedimientos computacionales mediante técnicas de inteligencia artificial. Sin embargo, difieren en la naturaleza de los problemas abordados, las arquitecturas empleadas y las métricas utilizadas para evaluar su desempeño. Por consiguiente, las mejoras reportadas no permiten establecer una superioridad generalizada de los algoritmos inteligentes, sino que evidencian ventajas específicas bajo condiciones definidas de implementación y evaluación. En consecuencia, la comparación de resultados requiere distinguir entre eficiencia temporal, reducción de operaciones matemáticas y precisión predictiva. Esta diferenciación fortalece la interpretación de las evidencias y permite reconocer tanto las contribuciones de los modelos inteligentes como las limitaciones asociadas con su generalización a otros problemas científicos y matemáticos.

4. DISCUSIÓN

El análisis de las 15 publicaciones científicas correspondientes al período 2019–2023 permitió identificar coincidencias y diferencias en los procedimientos utilizados para integrar inteligencia artificial y modelos matemáticos en la resolución de problemas complejos. Las investigaciones revisadas destacan la importancia de complementar los métodos computacionales convencionales mediante técnicas de aprendizaje automático capaces de representar relaciones no lineales, aproximar soluciones, optimizar algoritmos y realizar predicciones. Sin embargo, los estudios presentan diferencias en sus objetivos, enfoques metodológicos, formulaciones matemáticas y criterios de evaluación, por lo que sus resultados deben interpretarse de acuerdo con el tipo de evidencia disponible.

En relación con la integración de principios matemáticos y aprendizaje automático, Raissi et al. (2019) desarrollaron redes neuronales informadas por la física para resolver problemas directos e inversos asociados con ecuaciones diferenciales parciales, mientras que Li et al. (2021) propusieron un operador neuronal de Fourier para aprender correspondencias entre funciones y aproximar soluciones de familias de ecuaciones diferenciales. Ambos trabajos evidencian posibilidades para complementar los métodos numéricos tradicionales, aunque



difieren en sus formulaciones y procedimientos de entrenamiento. Las redes informadas por la física incorporan restricciones derivadas de las ecuaciones gobernantes, mientras que los operadores neuronales buscan aprender relaciones entre espacios funcionales a partir de datos de entrenamiento.

Esta distinción resulta relevante al considerar los aportes de Karniadakis et al. (2021), quienes analizaron diferentes alternativas para integrar conocimientos físicos y matemáticos dentro de los modelos de aprendizaje automático. Asimismo, Willard et al. (2023) examinaron procedimientos para combinar conocimientos científicos con herramientas computacionales inteligentes. Ambas publicaciones coinciden en reconocer el valor de integrar información previa sobre los sistemas estudiados, aunque presentan enfoques y alcances diferentes. Por su parte, Cuomo et al. (2022) identificaron desafíos relacionados con el entrenamiento y la convergencia de las redes neuronales informadas por la física. En consecuencia, la incorporación de principios científicos puede fortalecer la coherencia de los modelos, pero no garantiza por sí sola una solución precisa o computacionalmente eficiente para cualquier problema matemático.

Respecto a la optimización algorítmica y simulación computacional, Brunton et al. (2020) examinaron aplicaciones del aprendizaje automático en mecánica de fluidos, mientras que Kochkov et al. (2021) investigaron procedimientos para acelerar simulaciones de dinámica de fluidos computacional. Ambos trabajos coinciden en destacar el potencial de estas herramientas para complementar procesos de modelación y simulación. Sin embargo, Brunton et al. (2020) presentaron una revisión de diferentes enfoques, mientras que Kochkov et al. (2021) desarrollaron y evaluaron una propuesta computacional específica. Esta diferencia metodológica implica que sus contribuciones no deben interpretarse como evidencias experimentales equivalentes.

De manera complementaria, Fawzi et al. (2022) examinaron la utilización de aprendizaje por refuerzo para descubrir algoritmos de multiplicación de matrices, mientras que Degraeve et al. (2022) aplicaron aprendizaje por refuerzo profundo al control magnético de plasmas. Aunque estas investigaciones abordaron problemas de naturaleza diferente, ambas evidencian posibilidades de utilizar algoritmos inteligentes para explorar decisiones y soluciones bajo restricciones matemáticas o físicas. No obstante, los resultados corresponden a condiciones de evaluación particulares y no permiten afirmar que el aprendizaje



por refuerzo supere de manera uniforme a los procedimientos tradicionales en todos los problemas de optimización.

En cuanto a la predicción de sistemas naturales, Reichstein et al. (2019) examinaron las posibilidades del aprendizaje profundo para comprender procesos del sistema terrestre, destacando la importancia de integrar conocimientos científicos y datos observacionales. Por su parte, Bi et al. (2023) y Lam et al. (2023) desarrollaron modelos especializados de predicción meteorológica que demostraron resultados competitivos en evaluaciones de pronóstico global. Estas investigaciones coinciden en reconocer el potencial de las técnicas de aprendizaje automático para representar relaciones dinámicas complejas. Sin embargo, presentan diferencias en el propósito y alcance, debido a que Reichstein et al. (2019) desarrollaron una revisión interdisciplinaria, mientras que Bi et al. (2023) y Lam et al. (2023) evaluaron modelos predictivos específicos.

Las aplicaciones relacionadas con el descubrimiento científico también presentan contribuciones relevantes. Jumper et al. (2021) utilizaron aprendizaje profundo para predecir estructuras tridimensionales de proteínas, mientras que Merchant et al. (2023) aplicaron modelos computacionales al descubrimiento de estructuras cristalinas candidatas. Ambos estudios evidencian posibilidades de utilizar representaciones matemáticas y algoritmos inteligentes para abordar problemas científicos de elevada complejidad. No obstante, sus objetos de investigación, datos de entrenamiento y procedimientos de validación son diferentes. Por consiguiente, los resultados deben interpretarse dentro de cada disciplina, sin asumir que los niveles de precisión o desempeño son directamente comparables.

Desde una perspectiva metodológica, Rudin (2019) destacó la importancia de utilizar modelos interpretables en decisiones de alto impacto. Este planteamiento complementa las investigaciones centradas en precisión y eficiencia computacional, al reconocer que el desempeño predictivo debe examinarse junto con la transparencia y comprensión de los procedimientos algorítmicos. En problemas matemáticos y científicos complejos, la interpretación de los resultados adquiere especial relevancia cuando los modelos se utilizan para orientar decisiones técnicas, evaluar sistemas físicos o formular nuevas hipótesis.

En conjunto, las principales coincidencias entre las publicaciones se relacionan con las posibilidades de integrar conocimiento matemático, aprendizaje automático y procedimientos computacionales para abordar problemas que presentan múltiples



variables y relaciones complejas. Las diferencias se observan en las arquitecturas utilizadas, los tipos de datos, la formulación de los problemas, las métricas de evaluación y los recursos computacionales requeridos. Las investigaciones centradas directamente en ecuaciones diferenciales y optimización proporcionan evidencia sobre el desarrollo de métodos matemáticos, mientras que los estudios de aplicación científica permiten examinar su utilidad en contextos específicos.

Entre las principales limitaciones de esta revisión se encuentran el tamaño del corpus documental, la heterogeneidad de los enfoques metodológicos y la ausencia de métricas comunes para comparar el desempeño de los modelos. Asimismo, la incorporación de investigaciones pertenecientes a diferentes disciplinas limita la posibilidad de establecer conclusiones generales sobre la superioridad de determinados algoritmos. La ausencia de historiales completos de búsqueda bibliográfica y de una evaluación individual de calidad metodológica documentada también restringe la reproducibilidad del procedimiento de selección y la valoración comparativa de la evidencia científica.

A partir de estas limitaciones, se recomienda desarrollar investigaciones que comparen algoritmos de inteligencia artificial y métodos matemáticos convencionales bajo condiciones equivalentes, considerando precisión, tiempo de ejecución, costo computacional, capacidad de generalización e interpretabilidad. Asimismo, resulta necesario fortalecer los procedimientos de validación científica y promover el desarrollo de modelos híbridos que integren principios matemáticos, conocimientos físicos y técnicas de aprendizaje automático. Estas acciones permitirían ampliar la comprensión de las condiciones en las que la inteligencia artificial ofrece ventajas concretas para la resolución de problemas complejos.

5. CONCLUSIONES

La revisión bibliográfica de las 15 publicaciones científicas correspondientes al período 2019–2023 permitió identificar diferentes enfoques relacionados con la integración de la inteligencia artificial y los modelos matemáticos para la resolución de problemas complejos. Entre los principales se encuentran las redes neuronales informadas por principios físicos, los operadores neuronales, el aprendizaje automático científico, el aprendizaje por refuerzo, la simulación computacional y los modelos de predicción basados en aprendizaje profundo.



Las investigaciones examinadas evidenciaron oportunidades para complementar procedimientos matemáticos tradicionales mediante técnicas computacionales orientadas a aproximar soluciones de ecuaciones diferenciales, optimizar algoritmos, controlar sistemas dinámicos y desarrollar modelos predictivos. Sin embargo, los resultados varían según las características de los problemas estudiados, las arquitecturas utilizadas y las condiciones de evaluación, por lo que no es posible atribuir una efectividad uniforme a todos los enfoques. La integración de conocimientos matemáticos y principios físicos en los sistemas de aprendizaje automático representa una alternativa relevante para desarrollar modelos que incorporen información científica durante sus procesos de entrenamiento y evaluación. Asimismo, las aplicaciones en meteorología, dinámica de fluidos, estructuras proteicas y ciencia de materiales demuestran las posibilidades de utilizar herramientas inteligentes en diferentes disciplinas, aunque sus resultados requieren interpretación y validación de acuerdo con cada contexto.

Entre los principales desafíos identificados destacan los requerimientos computacionales, la dependencia de datos adecuados, las dificultades de entrenamiento y convergencia, la necesidad de validar las predicciones y las limitaciones relacionadas con la interpretabilidad de algunos modelos. Estas condiciones evidencian que la integración entre inteligencia artificial y matemáticas requiere procedimientos rigurosos de formulación, evaluación y análisis, sin sustituir automáticamente los fundamentos teóricos de los métodos convencionales.

REFERENCIAS BIBLIOGRÁFICAS

- Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X., & Tian, Q. (2023). Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, 619, 533–538. <https://doi.org/10.1038/s41586-023-06185-3>
- Brunton, S. L., Noack, B. R., & Koumoutsakos, P. (2020). Machine learning for fluid mechanics. *Annual Review of Fluid Mechanics*, 52, 477–508. <https://doi.org/10.1146/annurev-fluid-010719-060214>
- Cuomo, S., Schiano Di Cola, V., Giampaolo, F., Rozza, G., Raissi, M., & Piccialli, F. (2022). Scientific machine learning through physics-informed neural networks: Where we are



and what's next. *Journal of Scientific Computing*, 92, Article 88.
<https://doi.org/10.1007/s10915-022-01939-z>

Degrave, J., Felici, F., Buchli, J., Neunert, M., Tracey, B., Carpanese, F., Ewalds, T., Hafner, R., Abdolmaleki, A., de las Casas, D., Donner, C., Fritz, L., Galperti, C., Huber, A., Keeling, J., Tsimpoukelli, M., Kay, J., Merle, A., Moret, J.-M., . . . Riedmiller, M. (2022). Magnetic control of tokamak plasmas through deep reinforcement learning. *Nature*, 602, 414–419. <https://doi.org/10.1038/s41586-021-04301-9>

Fawzi, A., Balog, M., Huang, A., Hubert, T., Romera-Paredes, B., Barekatin, M., Novikov, A., Ruiz, F. J. R., Schrittwieser, J., Swirszcz, G., Silver, D., Hassabis, D., & Kohli, P. (2022). Discovering faster matrix multiplication algorithms with reinforcement learning. *Nature*, 610, 47–53. <https://doi.org/10.1038/s41586-022-05172-4>

Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., Tunyasuvunakool, K., Bates, R., Židek, A., Potapenko, A., Bridgland, A., Meyer, C., Kohl, S. A. A., Ballard, A. J., Cowie, A., Romera-Paredes, B., Nikolov, S., Jain, R., Adler, J., . . . Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596, 583–589. <https://doi.org/10.1038/s41586-021-03819-2>

Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., & Yang, L. (2021). Physics-informed machine learning. *Nature Reviews Physics*, 3, 422–440. <https://doi.org/10.1038/s42254-021-00314-5>

Kochkov, D., Smith, J. A., Alieva, A., Wang, Q., Brenner, M. P., & Hoyer, S. (2021). Machine learning–accelerated computational fluid dynamics. *Proceedings of the National Academy of Sciences*, 118(21), Article e2101784118. <https://doi.org/10.1073/pnas.2101784118>

Lam, R., Sanchez-Gonzalez, A., Willson, M., Wirnsberger, P., Fortunato, M., Alet, F., Ravuri, S., Ewalds, T., Eaton-Rosen, Z., Hu, W., Meroze, A., Hoyer, S., Holland, G., Vinyals, O., Stott, J., Pritzel, A., Mohamed, S., & Battaglia, P. (2023). Learning skillful medium-range global weather forecasting. *Science*, 382(6677), 1416–1421. <https://doi.org/10.1126/science.adi2336>

Li, Z., Kovachki, N., Azizzadenesheli, K., Liu, B., Bhattacharya, K., Stuart, A., & Anandkumar, A. (2021). *Fourier neural operator for parametric partial differential equations* [Artículo de conferencia]. International Conference on Learning Representations. <https://openreview.net/forum?id=c8P9NQVtmnO>



- Merchant, A., Batzner, S., Schoenholz, S. S., Aykol, M., Cheon, G., & Cubuk, E. D. (2023). Scaling deep learning for materials discovery. *Nature*, 624, 80–85. <https://doi.org/10.1038/s41586-023-06735-9>
- 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>
- Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566, 195–204. <https://doi.org/10.1038/s41586-019-0912-1>
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1, 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
- Willard, J., Jia, X., Xu, S., Steinbach, M., & Kumar, V. (2023). Integrating scientific knowledge with machine learning for engineering and environmental systems. *ACM Computing Surveys*, 55(4), Article 66. <https://doi.org/10.1145/3514228>

CONFLICTO DE INTERESES

No existe.

FINANCIAMIENTO

No aplica.

CONTRIBUCIÓN DE AUTORÍA (CRediT)

Conceptualización: Edwin Xavier Escobar Guanoluiza, Roberth Damián Guamani Guamani, Alex Fernando León Chancusig, Gladys Marisol Rodríguez Vallejo, María José Peñaranda Lóor.



Metodología: Edwin Xavier Escobar Guanoluisa, Roberth Damián Guamani Guamani, Alex Fernando León Chancusig, Gladys Marisol Rodríguez Vallejo, María José Peñaranda Loor.

Investigación: Edwin Xavier Escobar Guanoluisa, Roberth Damián Guamani Guamani, Alex Fernando León Chancusig, Gladys Marisol Rodríguez Vallejo, María José Peñaranda Loor.

Redacción – borrador original: Edwin Xavier Escobar Guanoluisa, Roberth Damián Guamani Guamani, Alex Fernando León Chancusig, Gladys Marisol Rodríguez Vallejo, María José Peñaranda Loor.

Redacción – revisión y edición: Edwin Xavier Escobar Guanoluisa, Roberth Damián Guamani Guamani, Alex Fernando León Chancusig, Gladys Marisol Rodríguez Vallejo, María José Peñaranda Loor.

