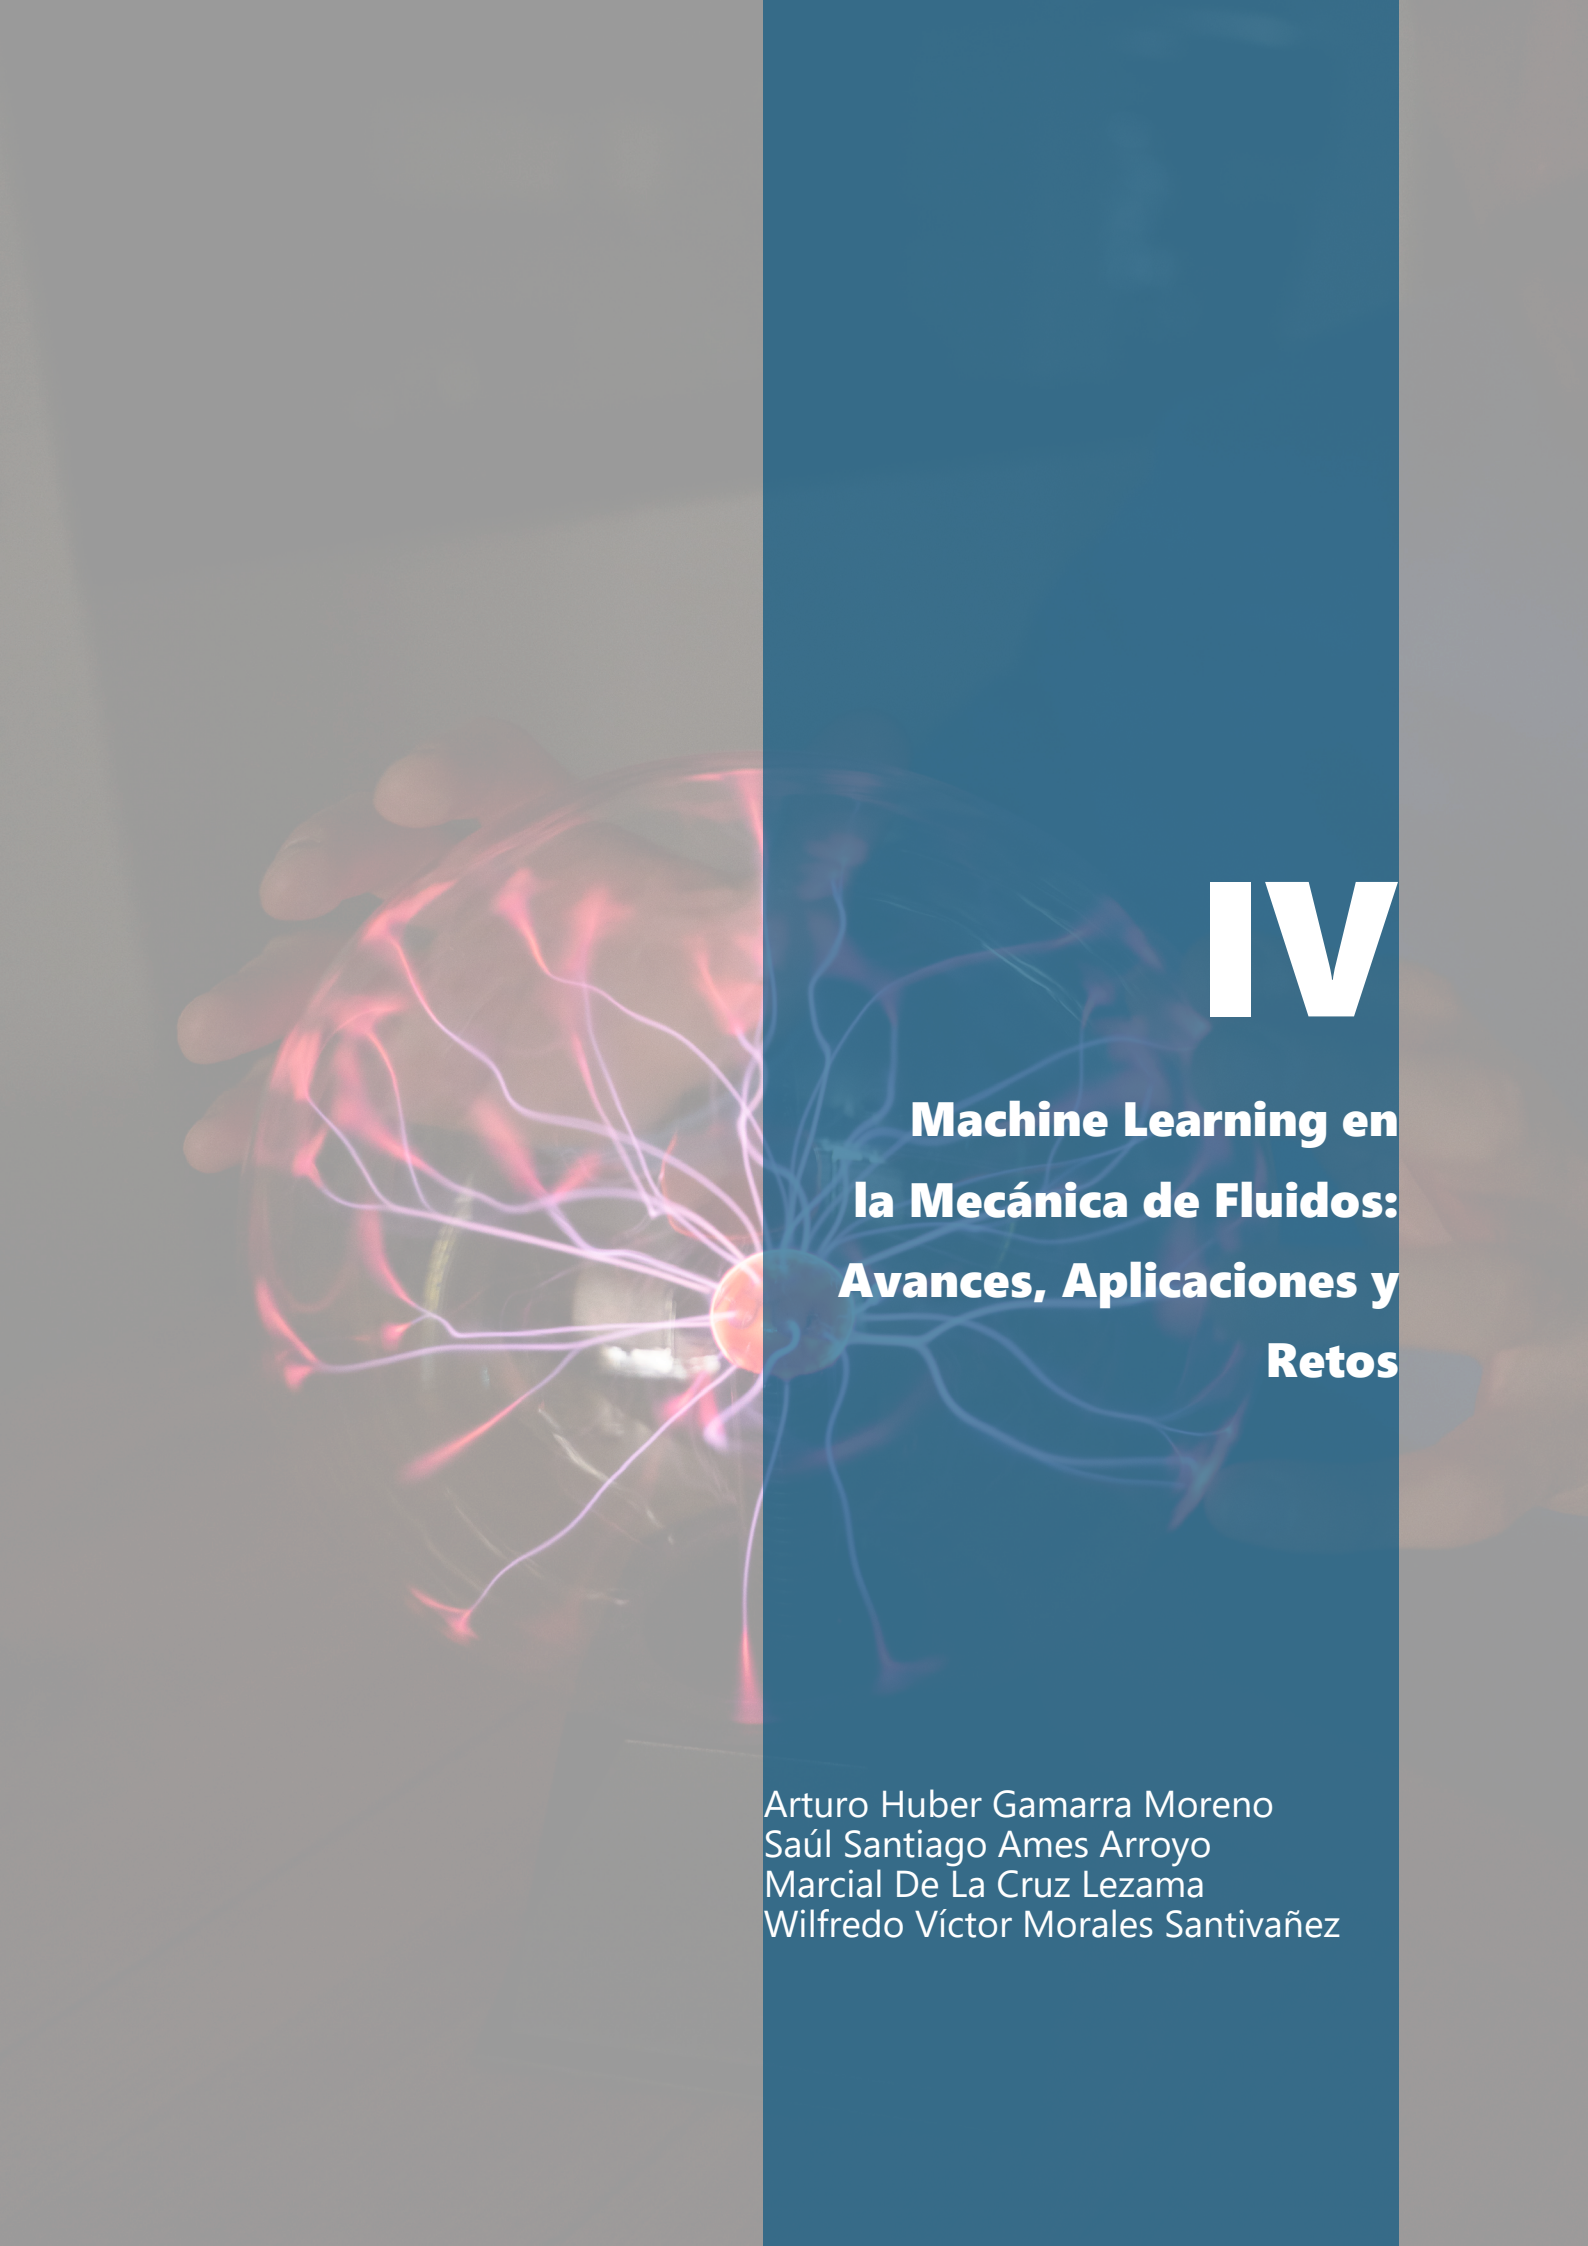

IV

Machine Learning en la Mecánica de Fluidos: Avances, Aplicaciones y Retos

Arturo Huber Gamarra Moreno
Saúl Santiago Ames Arroyo
Marcial De La Cruz Lezama
Wilfredo Víctor Morales Santivañez

IV

Machine Learning en la Mecánica de Fluidos: Avances, Aplicaciones y Retos

Arturo Huber Gamarra Moreno
Saúl Santiago Ames Arroyo
Marcial De La Cruz Lezama
Wilfredo Víctor Morales Santivañez

RESUMEN

El aprendizaje automático (ML) ha transformado la mecánica de fluidos, ofreciendo soluciones innovadoras para problemas complejos como la predicción, simulación y optimización de diseños. Gracias a su capacidad para procesar grandes volúmenes de datos y modelar relaciones no lineales, ML ha demostrado ser una herramienta eficaz para mejorar la eficiencia computacional y la precisión de los modelos. Ejemplos exitosos incluyen la predicción de flujos turbulentos mediante redes neuronales profundas y la optimización de perfiles aerodinámicos. Sin embargo, a pesar de sus logros, los modelos de ML aún enfrentan desafíos, como la falta de interpretabilidad física y dificultades en la generalización a nuevas condiciones. En el futuro, se espera que ML complemente los métodos tradicionales, especialmente mediante enfoques híbridos que integren conocimientos físicos. Para avanzar, es crucial fomentar la investigación interdisciplinaria y la creación de bases de datos abiertas y colaborativas. Estos esfuerzos permitirán mejorar la calidad de los modelos predictivos y expandir su aplicabilidad en áreas como la dinámica de fluidos computacional (CFD) y el diseño de sistemas fluidos en tiempo real.

Palabras clave: aprendizaje automático, mecánica de fluidos, redes neuronales, turbulencia, optimización de diseño.

ABSTRACT

Machine learning (ML) has transformed fluid mechanics, offering innovative solutions to complex problems such as design prediction, simulation, and optimization. Thanks to its ability to process large volumes of data and model nonlinear relationships, ML has proven to be an effective tool for improving computational efficiency and model accuracy. Successful examples include the prediction of turbulent flows using deep neural networks and the optimization of airfoils. However, despite its achievements, ML models still face challenges, such as lack of physical interpretability and difficulties in generalizing to new conditions. In the future, ML is expected to complement traditional methods, especially through hybrid approaches that integrate physical knowledge. Moving forward, it is crucial to foster interdisciplinary research and the creation of open and collaborative databases. These efforts will allow improving the quality of predictive models and expanding their applicability in areas such as computational fluid dynamics (CFD) and real-time fluid system design.

Keywords: machine learning, fluid mechanics, neural networks, turbulence, design optimization.

INTRODUCCIÓN

La mecánica de fluidos, como rama esencial de la física, desempeña un papel crucial en la ingeniería, las ciencias naturales y la tecnología. Sus aplicaciones abarcan desde el diseño de aeronaves y sistemas hidráulicos hasta la modelación de fenómenos climáticos y la dinámica de fluidos en procesos biológicos. Sin embargo, a pesar de los avances significativos en la simulación y el análisis de sistemas de fluidos, las metodologías tradicionales, como la dinámica de fluidos computacional (CFD, por sus siglas en inglés), enfrentan desafíos importantes. Estas técnicas, aunque poderosas, suelen ser computacionalmente costosas y, en muchos casos, limitadas en su capacidad para resolver problemas altamente no lineales y multiescalares, como la turbulencia o el flujo en medios porosos (Duraisamy, Iaccarino & Xiao, 2019).

En las últimas décadas, el auge del aprendizaje automático (ML, por sus siglas en inglés) ha abierto nuevas posibilidades para abordar los desafíos inherentes a la mecánica de fluidos. ML ha demostrado ser eficaz para procesar grandes volúmenes de datos, identificar patrones complejos y generar predicciones rápidas y precisas en

contextos altamente no lineales. Por ejemplo, enfoques como las redes neuronales profundas (DNNs) y el aprendizaje por refuerzo han sido utilizados para modelar flujos turbulentos, optimizar perfiles aerodinámicos y acelerar simulaciones computacionales (Kutz, 2017; Brunton, Noack & Koumoutsakos, 2020). Este potencial ha impulsado un interés creciente en la integración de ML con métodos tradicionales, dando lugar a enfoques híbridos que combinan conocimientos físicos con algoritmos avanzados de inteligencia artificial.

La motivación detrás de esta revisión radica en la creciente complejidad de los sistemas estudiados en mecánica de fluidos y en las limitaciones de las herramientas convencionales para abordarlos. Problemas como la modelación de flujos transitorios y la predicción en condiciones de contorno variables requieren enfoques más adaptativos y eficientes. En este contexto, ML emerge como una solución prometedora, capaz no solo de mejorar la precisión y la velocidad de las simulaciones, sino también de proporcionar nuevas perspectivas en el diseño y análisis de sistemas fluidos (Raissi, Perdikaris & Karniadakis, 2019). Sin embargo, su aplicación no está exenta de desafíos. Aspectos como la interpretación física de los modelos generados, la necesidad de grandes conjuntos de datos de alta calidad para el entrenamiento y la validación experimental de las predicciones representan áreas críticas para el desarrollo futuro.

El objetivo principal de este artículo es revisar los avances más destacados en la aplicación de ML en la mecánica de fluidos, destacando sus contribuciones más relevantes, así como sus limitaciones. Además, se busca identificar áreas prometedoras para futuras investigaciones y señalar los desafíos clave que deben superarse para consolidar el uso de ML en esta disciplina.

El manuscrito se estructura de la siguiente manera: primero, se describe la metodología empleada para seleccionar y analizar la literatura relevante. Luego, se presentan los resultados, destacando las aplicaciones más significativas de ML en la mecánica de fluidos, seguido de una discusión sobre las fortalezas, limitaciones y retos. Finalmente, se concluye con un resumen de los hallazgos principales y recomendaciones para investigaciones futuras.

METODOLOGÍA

Para llevar a cabo esta revisión, se realizó una exhaustiva búsqueda y selección de literatura científica relevante en el área de la mecánica de fluidos y su intersección con el aprendizaje automático (ML). Las fuentes principales de información incluyeron artículos de revistas científicas, revisiones exhaustivas y actas de conferencias especializadas publicadas en los últimos cinco años. Se priorizó la inclusión de trabajos que tuvieran un alto impacto en la disciplina, medido a través de citas y su influencia en el desarrollo de nuevas metodologías y aplicaciones. Asimismo, se seleccionaron estudios con aplicaciones destacadas en diversas áreas de la mecánica de fluidos, tales como la simulación numérica, la optimización de diseños y el modelado de flujos complejos (Duraisamy et al., 2019; Kutz, 2017).

La clasificación de los estudios se realizó según dos criterios clave: las técnicas de aprendizaje automático utilizadas y el ámbito de aplicación dentro de la mecánica de fluidos. Las técnicas de ML fueron agrupadas en categorías tales como redes neuronales profundas (DNN), redes neuronales convolucionales (CNN), aprendizaje por refuerzo y métodos basados en la teoría de grafos, entre otros (Raissi, Perdikaris & Karniadakis, 2019). En cuanto a los ámbitos de aplicación, se hizo una distinción entre estudios centrados en la turbulencia, la dinámica de fluidos computacional (CFD), y la optimización de diseños, áreas que han sido fuertemente impactadas por las innovaciones en ML (Brunton et al., 2020; Ling et al., 2016).

El enfoque de análisis consistió en comparar los resultados obtenidos mediante técnicas tradicionales de mecánica de fluidos y aquellos derivados de métodos basados en ML. Se evaluaron las ventajas y limitaciones de cada enfoque, considerando factores como la precisión, la eficiencia computacional y la capacidad para abordar problemas no lineales y multiescalares. Además, se identificaron oportunidades de mejora y áreas emergentes donde la integración de ML podría transformar la práctica de la mecánica de fluidos.

RESULTADOS

El uso de técnicas de aprendizaje automático (ML) en la mecánica de fluidos ha generado avances notables en diversas áreas, destacando la predicción y simulación, la

optimización de diseño, y la integración con métodos tradicionales como la dinámica de fluidos computacional (CFD). A continuación, se presentan los principales logros obtenidos hasta la fecha.

Predicción y Simulación

Uno de los avances más significativos en la mecánica de fluidos a través del ML es el desarrollo de modelos predictivos que permiten realizar simulaciones rápidas y precisas de flujos complejos. Las redes neuronales profundas (DNN) han demostrado ser herramientas poderosas para este propósito, capaces de modelar sistemas no lineales y multiescalares que son difíciles de abordar mediante métodos tradicionales. Por ejemplo, estudios recientes han utilizado DNN para predecir el comportamiento de flujos turbulentos en diversos entornos (Brunton et al., 2020). Estos modelos no solo proporcionan resultados de alta precisión, sino que también pueden reducir significativamente el tiempo computacional necesario para la simulación.

Los modelos basados en ML han sido particularmente eficaces en la simulación de fenómenos no lineales, como la transición de flujo laminar a turbulento, un problema clásico en la mecánica de fluidos. Al aplicar técnicas de aprendizaje profundo, es posible identificar patrones complejos en los datos que antes no podían ser modelados de manera efectiva. Ling et al. (2016) demostraron que, mediante redes neuronales, es posible modelar de forma más eficiente las ecuaciones de Navier-Stokes en problemas de turbulencia, superando las limitaciones de los modelos tradicionales basados en turbulencia. Este enfoque ha mostrado resultados muy prometedores en términos de precisión y tiempo de simulación, lo que sugiere un gran potencial para la mejora de la modelización de flujos turbulentos.

Optimización de Diseño

El aprendizaje automático también ha tenido un impacto considerable en la optimización de diseños, especialmente en aplicaciones aeroespaciales y de ingeniería civil, donde los flujos alrededor de estructuras son fundamentales. Los métodos de ML se han utilizado para mejorar perfiles aerodinámicos y sistemas de flujo, al aprender directamente de los datos de simulaciones previas. Por ejemplo, en el diseño de alas de aeronaves, las redes neuronales pueden predecir las mejores configuraciones geométricas para minimizar la resistencia al viento o maximizar la sustentación, sin nece-

sidad de realizar múltiples simulaciones de prueba y error (Raissi et al., 2019). Este tipo de optimización ha sido ampliado a otros dominios como la hidráulica, donde los algoritmos de ML han permitido mejorar la eficiencia de los sistemas de flujo en canales y tuberías.

Además, el uso de algoritmos de optimización basados en ML, como los algoritmos genéticos y el aprendizaje por refuerzo, ha mejorado la capacidad de encontrar soluciones óptimas en problemas complejos de diseño. Estos enfoques pueden explorar un espacio de diseño mucho más amplio y realizar ajustes en tiempo real, lo que resulta en una optimización más eficiente comparado con los métodos convencionales (Jha et al., 2020).

Integración con CFD

Uno de los desarrollos más destacados ha sido la integración de ML con CFD, lo que permite reducir significativamente la carga computacional asociada con las simulaciones de fluidos complejos. Mientras que las simulaciones CFD tradicionales requieren grandes recursos computacionales y tiempos de ejecución prolongados, el uso de modelos basados en ML puede acelerar este proceso, especialmente cuando se incorporan datos previos obtenidos de simulaciones pasadas. Esta integración ha abierto nuevas posibilidades para aplicaciones en tiempo real, como la simulación de flujos en dispositivos interactivos o sistemas de control en ingeniería.

Una de las aplicaciones más interesantes de esta integración son los métodos híbridos, que combinan las fortalezas del CFD con las capacidades predictivas del ML. En estos enfoques, las simulaciones CFD se utilizan para obtener un conjunto inicial de datos, mientras que el ML se emplea para refinar los resultados y predecir el comportamiento bajo diferentes condiciones. Este enfoque ha sido utilizado en diversos estudios para mejorar la precisión de las simulaciones de flujos turbulentos y aumentar la eficiencia computacional en la simulación de flujos en geometrías complejas (Duraisamy et al., 2019; Kutz, 2017).

Impactos Medidos

Los impactos más notables de la aplicación de ML en la mecánica de fluidos incluyen un incremento significativo en la eficiencia computacional y una mejora en la precisión de los modelos predictivos. En términos de eficiencia, los modelos basados en ML permiten una reducción considerable en el tiempo requerido para obtener resultados de simulación, lo que facilita la ejecución de simulaciones a gran escala y

el análisis de múltiples escenarios sin la necesidad de una infraestructura computacional costosa. Esto ha sido especialmente valioso en aplicaciones industriales donde el tiempo y los costos de simulación son factores críticos (Raissi et al., 2019).

Además, los modelos de ML han demostrado ser capaces de lograr una precisión similar o superior a la de los métodos tradicionales en ciertos problemas complejos. En particular, la capacidad de ML para aprender de grandes volúmenes de datos ha permitido mejorar la exactitud en la predicción de flujos turbulentos y otros fenómenos no lineales, donde los enfoques clásicos a menudo fallan en capturar los detalles finos del comportamiento del fluido (Brunton et al., 2020). Esta precisión ha sido crucial en aplicaciones que requieren una alta fidelidad en las simulaciones, como el diseño de aeronaves o la simulación de procesos industriales.

DISCUSIÓN

El uso de aprendizaje automático (ML) en la mecánica de fluidos ha revelado una serie de fortalezas y limitaciones, además de presentar desafíos y oportunidades para futuras investigaciones. A continuación, se abordan los puntos clave que surgen al comparar estos enfoques con los métodos tradicionales de simulación y modelado en la mecánica de fluidos.

Fortalezas del ML en mecánica de fluidos

Una de las principales fortalezas de ML en la mecánica de fluidos es su capacidad para procesar grandes volúmenes de datos y manejar la alta dimensionalidad inherente a los problemas complejos de fluidos. Los modelos de ML, especialmente las redes neuronales profundas (DNN), son capaces de aprender de grandes conjuntos de datos generados por simulaciones o experimentos, permitiendo la captura de relaciones no lineales y multiescalares que son difíciles de modelar con los enfoques tradicionales. Por ejemplo, los modelos de ML han sido exitosos en la predicción de flujos turbulentos, donde las relaciones entre las variables son extremadamente complejas (Ling et al., 2016). Esta capacidad de procesar datos complejos permite que los modelos basados en ML puedan predecir comportamientos de flujo con una precisión similar o superior a la de los métodos tradicionales, pero con una reducción significativa en los tiempos de simulación (Brunton et al., 2020).

Otra ventaja importante es la automatización en el descubrimiento de patrones y modelos. Los algoritmos de ML son capaces de identificar patrones ocultos en grandes conjuntos de datos sin la intervención humana, lo que puede acelerar significativamente el proceso de modelado. Esto es especialmente útil cuando se enfrentan a sistemas fluidos con condiciones de contorno altamente variables o cuando las soluciones analíticas son difíciles de obtener. La capacidad de los modelos de ML para adaptarse y aprender de los datos a medida que se recopilan nuevos datos mejora su rendimiento de manera continua y autónoma (Duraisamy et al., 2019).

Limitaciones

A pesar de sus fortalezas, el uso de ML en la mecánica de fluidos enfrenta varias limitaciones significativas. Una de las principales es la falta de interpretabilidad física de los modelos generados. Mientras que los métodos tradicionales de simulación, como la dinámica de fluidos computacional (CFD), están basados en principios físicos bien entendidos, los modelos de ML a menudo funcionan como "cajas negras", lo que dificulta la interpretación física de sus resultados. Esta falta de explicabilidad plantea problemas cuando se intenta entender o validar los resultados en función de principios físicos, lo que puede limitar la confianza en su aplicación en problemas donde la comprensión detallada del fenómeno físico es crucial (Raissi et al., 2019). Esta es una de las áreas que más preocupa en la integración de ML con la mecánica de fluidos, especialmente cuando se aplican a sistemas complejos como la turbulencia.

Otra limitación importante es la dificultad de generalización de los modelos entrenados en ML a diferentes condiciones de contorno. Aunque los modelos basados en ML pueden ser muy precisos cuando se entrenan con grandes cantidades de datos representativos, su desempeño puede deteriorarse significativamente cuando se les presenta un conjunto de datos con condiciones no vistas previamente. Este desafío es particularmente relevante en problemas que requieren un alto grado de generalización, como en la simulación de flujos en condiciones extremas o desconocidas (Brunton et al., 2020).

Retos futuros

Para superar estas limitaciones, uno de los principales retos es la incorporación de conocimientos físicos en los modelos de ML. El enfoque de "Physics-Informed Machine Learning" (PIML) es prometedor, ya que integra principios físicos directamente en los algoritmos de ML. Este enfoque no solo mejora la precisión y la estabilidad del modelo, sino que también facilita la interpretabilidad de los resultados. Varios estudios han demostrado que la integración de ecuaciones diferenciales y leyes físicas en los modelos de ML puede mejorar la generalización y proporcionar soluciones más

robustas en sistemas fluidos (Raissi et al., 2019).

Otro desafío importante es la disponibilidad de datos de calidad para entrenar los modelos de ML. Si bien los avances en simulación y recopilación de datos experimentales han mejorado la situación, todavía existe una falta de bases de datos suficientemente grandes y diversas para abordar todos los posibles casos en la mecánica de fluidos. La creación de bases de datos colaborativas y abiertas podría ser una solución importante para avanzar en esta área.

Finalmente, la validación experimental sigue siendo un reto crítico. A pesar de los avances en la precisión de los modelos de ML, su validación experimental en situaciones reales es aún limitada. Los resultados obtenidos mediante ML deben ser validados mediante experimentos controlados para garantizar su fiabilidad y aplicabilidad en la práctica (Kutz, 2017).

Comparación con métodos tradicionales

Cuando se compara el ML con los métodos tradicionales, como el CFD, es evidente que ML ofrece ventajas significativas en términos de eficiencia computacional. Los métodos basados en ML pueden realizar predicciones mucho más rápidamente, lo que los hace útiles en aplicaciones donde el tiempo es un factor crítico, como en el diseño aerodinámico o el análisis de flujos en tiempo real (Duraisamy et al., 2019). Sin embargo, en ciertos problemas donde se requiere una precisión muy alta y un control detallado de las condiciones de contorno, los métodos tradicionales siguen siendo más adecuados, ya que están basados en teorías físicas bien fundamentadas y ofrecen resultados explicables y fácilmente interpretables.

CONCLUSIONES

El uso del aprendizaje automático (ML) en la mecánica de fluidos ha demostrado tener un potencial transformador, proporcionando soluciones innovadoras en áreas clave como la predicción, la simulación y la optimización. Ejemplos destacados, como la predicción de flujos turbulentos mediante redes neuronales profundas y la optimización de diseños aerodinámicos, han mostrado cómo ML puede superar las limitaciones de los métodos tradicionales en términos de eficiencia computacional y precisión en sistemas complejos (Brunton et al., 2020; Ling et al., 2016). Estos avances abren nuevas posibilidades para abordar problemas fluidos no lineales y multiescalares de manera más rápida y eficaz.

A medida que la integración de ML con la mecánica de fluidos continúa evolucionando, se anticipa que ML se convertirá en una herramienta complementaria a los

enfoques tradicionales, permitiendo explorar una gama más amplia de problemas complejos. Este enfoque híbrido puede ser crucial en campos como el diseño aerodinámico y la simulación en tiempo real (Duraisamy et al., 2019).

Se recomienda una mayor inversión en investigaciones interdisciplinarias que combinen el conocimiento físico con técnicas avanzadas de ML. Además, el desarrollo de bases de datos abiertas y colaborativas es esencial para acelerar el progreso en este campo y garantizar la disponibilidad de datos de calidad para el entrenamiento de modelos predictivos (Raissi et al., 2019).

REFERENCIAS

Brunton, S. L., Noack, B. R., & Koumoutsakos, P. (2020). Machine learning for fluid mechanics. *Annual Review of Fluid Mechanics*, 52, 477-508.

Duraisamy, K., Iaccarino, G., & Xiao, H. (2019). Turbulence modeling in the age of data. *Annual Review of Fluid Mechanics,* 51, 357-377.

Jha, P., Hussain, S., & Park, J. (2020). A hybrid deep learning framework for aerodynamics design optimization. J*ournal of Aircraft,* 57(4), 720-730.

Kutz, J. N. (2017). Deep learning in fluid dynamics. J*ournal of Fluid Mechanics,* 814, 1-4.

Ling, J., Kurzawski, A., & Templeton, J. (2016). Reynolds-averaged turbulence modeling using deep neural networks with embedded invariance. *Journal of Fluid Mechanics*, 807, 155-166.

Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving partial differential equations. *Journal of Computational Physics*, 378, 686-707.