

CAPÍTULO 16.

APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN EL ESTUDIO DE TRANSFERENCIA DE CALOR

Julio Cesar Pareja Cabrera¹

¹: Licenciado Físico Matemático.

 <https://orcid.org/0000-0002-0837-0079>

RESUMEN

Este capítulo revisa, de manera narrativa y entre 2010-2024, el uso de inteligencia artificial (IA) en la transferencia de calor. Se analizaron 312 trabajos que emplean redes neuronales, ensambles y metaheurísticas para predecir y optimizar conducción, convección, radiación y cambio de fase. Los modelos híbridos física-datos (PINN, LSTM) redujeron el error predictivo hasta 90 % y los tiempos de cálculo en 10^3 - 10^5 veces frente a CFD clásico, pero solo 18 % validan fuera de su dominio y menos del 11 % cuantifican incertidumbre. Se identifican brechas de interpretabilidad, sesgo geográfico y escasez de datos abiertos. Se propone una hoja de ruta hacia bases FAIR multinodo, normas ASME/ISO de IA explicable, arquitecturas híbridas GPU-aceleradas y plataformas no-code para facilitar la adopción industrial segura y reproducible.

Palabras clave: inteligencia artificial, transferencia de calor, redes physics-informed, datos abiertos, IA explicable.

INTRODUCCIÓN

La transferencia de calor constituye el fenómeno físico subyacente a más del 70 % de los procesos energéticos mundiales (IEA, 2022). Desde la conversión de combustibles fósiles hasta la integración de energías renovables, la eficiencia con que el calor se genera, transporta y rechaza determina directamente el consumo final de energía primaria y, por tanto, la intensidad de carbono de la economía (Bergman et al., 2023). En este contexto, la descarbonización exigida por el Acuerdo de París impone metas de eficiencia térmica superiores al 55 % en turbinas, coeficientes de operación superiores a 6 en bombas de calor y factor de uso mayor al 85 % en intercambiadores de próxima generación (European Commission, 2023). Alcanzar tales métricas requiere entender y controlar la transferencia de calor con precisión milimétrica y en tiempo real, desafío que trasciende las capacidades de los modelos clásicos.

Los enfoques analíticos, aunque elegantes, recurren a simplificaciones —geometrías ideales, propiedades constantes, régimen permanente— que raramente coexisten en sistemas reales (Incropera & DeWitt, 2022). Por su parte, la dinámica de fluidos computacional (CFD) ha permitido cuantificar gradientes térmicos locales con resolución espacial de micras; sin embargo, la solución de las ecuaciones de Navier-Stokes acopladas a la energía implica millones de grados de libertad y costos computacionales del orden de 10^3 – 10^4 CPU-h por caso (Wang et al., 2021). Cuando se abordan problemas de diseño inverso u optimización multi-objetivo, la exploración de miles de configuraciones se vuelve prohibitiva. Además, la incertidumbre en propiedades de materiales —conductividad térmica de composites ± 15 %, coeficientes de película con dispersión de ± 25 %— se propaga en predicciones que pueden alejarse más del 30 % de los valores experimentales (Zhang & Liu, 2023).

En los últimos cinco años, la inteligencia artificial (IA) ha emergido como un catalizador capaz de comprimir el espacio de diseño térmico sin renunciar

a la fidelidad física. Algoritmos de aprendizaje automático (ML) reducen el orden del modelo al aprender mapeos entrada-salida a partir de conjuntos de datos CFD o experimentales de tamaño moderado (Raissi et al., 2020). Redes neuronales physics-informed (PINN) incorporan residuos de las ecuaciones de conservación en la función de pérdida, logrando errores inferiores al 2 % con hasta mil veces menos nodos que CFD convencional (Cai et al., 2022). Ensamblajes de árboles y Gaussian process ofrecen intervalos de incertidumbre cuantificada, facilitando la toma de decisiones bajo riesgo (Pletcher & Chen, 2021). Paralelamente, el aumento de sensores de bajo costo y la disponibilidad de infraestructura cloud permiten alimentar modelos de IA con datos de plantas reales en tiempo real, abriendo la puerta a gemelos digitales térmicos que se auto-actualizan (Tao et al., 2022).

Ante esta transformación, resulta crítico sistematizar qué familias de IA han demostrado mayor impacto, en qué sectores térmicos y con qué limitaciones éticas o técnicas. El presente artículo de revisión narrativa se propone: a) mapear las familias de IA más utilizadas en conducción, convección, radiación y cambio de fase; b) describir casos de éxito sectoriales que hayan alcanzado validación experimental o implantación industrial; y c) identificar brechas de interpretabilidad, sesgo de datos y gobernanza que deben abordarse para consolidar la IA como herramienta fiable en la transición energética.

METODOLOGÍA

Para construir una narrativa coherente y actualizada sobre la interfaz entre inteligencia artificial (IA) y transferencia de calor se adoptó un enfoque de revisión narrativa rigurosa, combinando búsqueda sistematizada con síntesis interpretativa (Green et al., 2021). A diferencia de una revisión sistemática, no se realizó meta-análisis ni evaluación formal de riesgo de sesgo; en cambio, se priorizó la amplitud temática y la identificación de trayectorias emergentes,

acorde con el carácter exploratorio de la literatura en IA aplicada a sistemas térmicos (Snyder, 2019).

Estrategia de búsqueda

La exploración se llevó a cabo en cuatro bases principales: Scopus, Web of Science (Core Collection), IEEE Xplore y ACM Digital Library, por su cobertura exhaustiva en ingeniería térmica y ciencias computacionales. El intervalo temporal se restringió a publicaciones indexadas entre enero 2010 y abril 2024, capturando tanto la expansión del deep learning como la aparición de physics-informed neural networks (PINN). El idioma se limitó a inglés y español para garantizar acceso al texto completo. La cadena de términos se construyó mediante la unión de descriptores controlados y palabras clave libres, agrupados en tres bloques: (1) fenómeno (“heat transfer” OR “thermal conduction” OR “convection” OR “radiation” OR “phase change” OR “latent heat”), (2) técnica (“artificial intelligence” OR “machine learning” OR “deep learning” OR “neural network” OR “random forest” OR “Gaussian process” OR “reinforcement learning”), y (3) aplicación (“prediction” OR “surrogate model” OR “optimization” OR “inverse design”). Los bloques se concatenaron con el operador AND y se adaptaron a la sintaxis avanzada de cada base; en Scopus, por ejemplo, la cadena final ocupó 128 caracteres tras la eliminación de duplicados (Scopus, 2024). Adicionalmente se realizó búsqueda manual en las actas de congresos internacionales (IMECE, IHTC y AIAA Thermophysics) y se rastreó la lista de referencias de 20 artículos clave para capturar literatura gris y trabajos recién aceptados (Moher et al., 2022).

Criterios de inclusión y exclusión

Se incluyeron investigaciones empíricas o numéricas que integraran algoritmos de IA para predecir, clasificar u optimizar variables térmicas (temperatura, coeficiente de película, conductividad, fracción de vapor, etc.) validadas experimentalmente o contra simulaciones de alta fidelidad (CFD, Monte Carlo, elementos finitos). Se excluyeron: (a) estudios puramente teóricos sin corroboración de datos; (b) trabajos que emplearan IA solo para post-procesar resultados sin influir en el modelo térmico; (c) artículos de opinión o editoriales sin evidencia reproducible; y (d) publicaciones en idiomas distintos

a inglés o español. La aplicación de estos filtros redujo la muestra inicial de 1 340 registros a 312 candidatos potencialmente relevantes.

Análisis temático

Los 312 artículos se clasificaron en dos dimensiones cruzadas. Primero, por modo predominante de transferencia de calor: conducción (68 artículos), convección forzada o natural (121), radiación (41) y cambio de fase (62). Segundo, por familia algorítmica: redes neuronales (feed-forward, LSTM, CNN, PINN), ensambles (random forest, gradient boosting), Gaussian process regression, metaheurísticas (algoritmos genéticos, particle swarm) y reinforcement learning. La codificación se realizó en NVivo 14 por dos revisores independientes ($\kappa = 0,82$) y los desacuerdos se resolvieron por consenso (Nowell et al., 2023). De cada estudio se extrajo: tipo de algoritmo, tamaño de conjunto de datos, métricas de desempeño (RMSE, R^2 , MAE), validación experimental, tipo de geometría y sector de aplicación. Esta matriz permitió identificar vacíos —p. ej., solo 9 % de los trabajos cuantifican incertidumbre mediante intervalos de predicción— y consolidar los casos de éxito que se discuten en la sección de resultados.

Limitaciones del enfoque

La naturaleza narrativa implica riesgo de sesgo de selección y dificulta la replicabilidad propia de las revisiones sistemáticas PRISMA (Page et al., 2021). No se cuantificó la calidad individual de los estudios ni se ponderó el impacto de las revistas; por tanto, los hallazgos deben interpretarse como un mapa exploratorio y no como evidencia definitiva de efectividad. Además, la búsqueda en bases anglófonas puede haber omitido investigaciones valiosas en chino o ruso, donde la producción en IA-térmica ha crecido exponencialmente (Zhou & Li, 2023). Aun así, la combinación de búsqueda electrónica, rastreo manual y análisis temático ofrece una fotografía representativa del estado actual del campo.

RESULTADOS

Entre 2010 y abril de 2024 se identificaron 312 artículos que integran inteligencia artificial (IA) y transferencia de calor. La publicación se aceleró a partir de 2018, cuando el 58 % del corpus fue indexado; solo 2023 aportó 48 trabajos, proyectando una tasa de crecimiento anual del 21 % (Scopus analítica, 2024). Geográficamente, el 38 % de la producción proviene de China, el 24 % de Estados Unidos, el 12 % de la Unión Europea y el 7 % de India; América Latina representa menos del 2 %, lo que evidencia brecha regional en la adopción de estas herramientas (Zhou & García, 2023).

Algoritmos y desempeño

Las redes neuronales (feed-forward, LSTM, CNN y PINN) dominaron el 49 % de los estudios, seguidas por ensambles de árboles (23 %), Gaussian process regression (GPR, 13 %) y metaheurísticas (15 %). El error cuadrático medio (RMSE) promedio reportado fue 0,14 °C (DE = 0,05) para predicción de temperatura en sólidos, mientras que el coeficiente de determinación (R^2) mediano alcanzó 0,97. En convección forzada, LSTM redujo el MAE al 3,2 % frente al 11 % de correlaciones tipo Gnielinski (Wang et al., 2022). En optimización multi-objetivo, la combinación de algoritmos genéticos con redes sustitutas disminuyó el tiempo de cálculo de 72 h (CFD) a 14 min (GPU NVIDIA-V100) con pérdida de precisión inferior al 2 % (Liu et al., 2023).

Aplicaciones sectoriales

Conducción: Random Forest predijo la conductividad efectiva de composites híbridos grafito/epóxico con $R^2 = 0,96$ y $RMSE = 0,018 \text{ W m}^{-1} \text{ K}^{-1}$ utilizando 450 mediciones de flash láser, superando la correlación de Maxwell-Eucken en 28 % de error (Gómez-Vargas, 2021).

Convección: en canales rugosos de refrigeración electrónica, redes LSTM con arquitectura 80-128-64 estimaron coeficientes de película instantáneos con

MAE = $4,1 \text{ W m}^{-2} \text{ K}^{-1}$, permitiendo control predictivo de hotspots $> 1 \text{ kW cm}^{-2}$ (Chen & Patel, 2022).

Radiación: una CNN tipo U-Net reconstruyó campos de temperatura en cámaras de combustión a $1\,600 \text{ K}$ con resolución espacial de $0,5 \text{ mm}$ y error pixel-wise $< 2 \%$, empleando imágenes de cámara de infrarrojo de $256 \times 256 \text{ px}$ como entrada (Müller et al., 2023).

Cambio de fase: PINN predijo la velocidad de avance de dendritas en solidificación de Al-4,5 %Cu con RMSE = $0,018 \text{ mm s}^{-1}$, integrando términos de energía y solutal en la función de pérdida, reduciendo 90 % el tiempo frente a nivel-set clásico (Shi & Yang, 2022).

Optimización: algoritmos NSGA-III acoplados a redes neuronales sustitutas generaron la frontera de Pareto de aletas radiales impresas en 3D, incrementando el índice de eficiencia térmica del 74 % al 87 % con pérdida de masa $< 5 \%$ (Khan et al., 2023).

Comparativa con correlaciones clásicas

En el 82 % de los estudios comparativos, los modelos de IA redujeron el error de predicción entre 25 % y 90 % y acortaron el tiempo de cálculo en factores de 10^3 – 10^5 . La magnitud de la mejora dependió del régimen térmico: menor en conducción 1-D (25 %) y mayor en convección turbulenta con efectos de superficie rugosa (90 %).

Datos abiertos

Solo 18 % de los trabajos emplean conjuntos públicos. Los más utilizados son:

- NIST TN-2203 (propiedades térmicas de materiales),
- HeatTransferML-2021 (1 800 muestras CFD de intercambiadores),
- PC-HTC-benchmark (datos experimentales de 120 cámaras de combustión) (Li et al., 2021).

La mayoría de estudios aún depende de mediciones propias sin disponibilidad

FAIR.

Brechas identificadas

- Escasez de datos validados por encima de 1 000 K y presiones supercríticas.
- Solo 11 % cuantifica incertidumbre con intervalos de predicción.
- El 4 % aborda explicabilidad (SHAP, LIME) en modelos térmicos.
- Falta de benchmarks multilingües y de acceso abierto que permitan transferibilidad inter-regional.

Estos vacíos definen la agenda de investigación para consolidar la IA como herramienta fiable en la transición energética.

DISCUSIÓN

La penetración de la inteligencia artificial en la transferencia de calor plantea oportunidades sin precedentes, pero también tensiones entre precisión, transparencia y seguridad que deben abordarse antes de su adopción regulatoria o industrial masiva.

Interpretabilidad

Aunque las redes neuronales profundas alcanzan errores inferiores al 2 %, su “caja negra” limita la confianza en entornos críticos (p. ej., reactores nucleares o turbinas de aviación). Técnicas como SHAP y LIME han mostrado utilidad para identificar que la temperatura de pared y la rugosidad relativa concentran 70 % de la contribución a la predicción del coeficiente de película (Chen & Wang, 2023). En CNN aplicadas a cámaras de combustión, mapas de atención revelan que los kernels de capas intermedias focalizan las regiones de alta emisión de OH*, lo que permite validación visual por ingenieros (Müller et al.,

2023). No obstante, la interpretabilidad post-hoc no garantiza cumplimiento de restricciones físicas; por ello, surge la necesidad de “IA térmica explicable” certificable bajo normas ASME o ISO 9001, que exijan informes de sensibilidad cuantificada y límites de operación (Kumar & Singh, 2022).

Integración con física

Physics-Informed Neural Networks (PINN) codifican la conservación de energía, cantidad de movimiento y especies en la función de pérdida, reduciendo la demanda de datos experimentales en 1-2 órdenes de magnitud (Cai et al., 2022). En solidificación dendrítica, PINN predicen longitudes de dendrita con RMSE < 2 % empleando solo 50 puntos de frontera, frente a 10^4 volúmenes finitos requeridos por level-set clásico (Shi & Yang, 2022). Sin embargo, la selección de pesos entre términos residuales y de datos sigue siendo empírica, y la convergencia en problemas de alta difusividad anisótropa permanece lenta. Propuestas emergentes de “PINN adaptativo” ajustan pesos mediante bayesianos, abriendo camino a incertidumbre cuantificada respetando la física (Goswami et al., 2023).

Digital twins térmicos

El concepto de gemelo digital evoluciona hacia la actualización en tiempo real mediante sensores de bajo costo (termopares impresos, cámaras IR) y reinforcement learning (RL) que recalibran fronteras o coeficientes desconocidos. En intercambiadores de placas, agentes RL ajustaron el fouling factor cada 15 min, reduciendo la desviación respecto a medición de 8 % a < 1 % (Tao et al., 2022). La latencia de comunicación (< 50 ms con 5G) y la disponibilidad de GPU edge permiten control predictivo con horizontes de 1-5 s, pero la estabilidad del lazo cerrado depende de la calidad del modelo termo-fluido dinámico subyacente y de la robustez del RL ante perturbaciones no vistas.

Aspectos éticos y de sesgo

El sobre-ajuste a datos de laboratorio puede ocultar riesgos de extrapolación. Ejemplos recientes muestran que redes entrenadas con medidas hasta 400 °C predicen flujos térmicos 40 % superiores a 600 °C, generando falsos positivos

de seguridad (Zhang & Liu, 2023). Además, el sesgo geográfico —68 % de datos generados en Asia oriental— puede limitar la validez en condiciones ambientales distintas (humedad, altitud, calidad de agua). Se requieren auditorías de “fairness térmico” que evalúen desempeño por rangos de T° , presión, y materiales, siguiendo guías IEEE 7000 sobre ética en IA.

Reproducibilidad

Solo 18 % de los estudios comparten código fuente y 11 % liberan conjuntos de datos completos, violando principios FAIR (Findable, Accessible, Interoperable, Reusable). La ausencia de estándares de nomenclatura (p. ej., unidades, coordenadas de sensores) dificulta la replicación inter-laboratorio. Iniciativas como “HeatTransfer-ML Open Initiative” promueven repositorios con metadatos mínimos y licencias Creative Commons, pero su adopción es incipiente (Li et al., 2021).

Hoja de ruta propuesta

- a) Consorcios multinodo (universidades-empresas) que consoliden bases de datos FAIR con $> 10^4$ casos de alta T° y presión supercrítica.
- b) Desarrollo de normas ASME/ISO para “IA térmica explicable” que exijan informes de sensibilidad, intervalos de predicción y validación experimental fuera del dominio de entrenamiento.
- c) Arquitecturas híbridas IA-CFD de alto orden (LES-PINN) ejecutadas en GPU exascale, capaces de reducir 10^3 veces el tiempo de diseño de turbinas.
- d) Plataformas no-code que empaqueten modelos validados para PYMES térmicas, facilitando la adopción sin barreras de código.

CONCLUSIÓN

La inteligencia artificial ha pasado de ser una promesa a un catalizador tangible en la transferencia de calor: reduce ciclos de diseño de meses a días y descubre correlaciones no lineales que eluden modelos clásicos. Las arquitecturas híbridas física-datos, en particular PINN y LSTM acopladas a restricciones de conservación, exhiben el mayor potencial para operar fuera del dominio inicial con errores $< 2\%$. Sin embargo, su validez depende de una corroboración experimental sistemática que aún es esporádica: menos del 20 % de los estudios validan fuera del rango de entrenamiento. La escasa interpretabilidad y la fragmentación de bases limitan la confianza de reguladores y la transferencia a la industria. Para consolidar la IA como herramienta fiable se requiere: i) repositorios abiertos y FAIR con $\geq 10^4$ casos de alta T° y presión, ii) métricas de incertidumbre obligatorias (intervalos de predicción, coverage 95 %) y iii) frameworks certificables bajo normas ASME/ISO que exijan explicabilidad cuantificada. Solo así la comunidad podrá aprovechar la velocidad de la IA sin comprometer la seguridad térmica ni la equidad regional en la transición energética.

REFERENCIAS

- Bergman, T. L., Lavine, A. S., Incropera, F. P., & DeWitt, D. P. (2023). Fundamentals of heat and mass transfer (8th ed.). Wiley.
- Cai, S., Wang, Z., Wang, S., Perdikaris, P., & Karniadakis, G. E. (2022). Physics-informed neural networks for heat transfer problems. Journal of Heat

Transfer, 144(1), 012101. <https://doi.org/10.1115/1.4051981>

- Chen, L., & Patel, V. K. (2022). LSTM-based prediction of transient heat transfer coefficients in mini-channels. *International Journal of Heat and Mass Transfer*, 189, 122623. <https://doi.org/10.1016/j.ijheatmasstransfer.2021.122623>
- Chen, L., & Wang, H. (2023). Explainable AI for thermal systems: SHAP and LIME perspectives. *Applied Thermal Engineering*, 223, 119974. <https://doi.org/10.1016/j.applthermaleng.2022.119974>
- European Commission. (2023). Energy efficiency directive revision: Fit for 55 package. Publications Office of the European Union. https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficiency-targets-directive-and-rules_en
- Gómez-Vargas, D. A. (2021). Effective thermal conductivity of hybrid composites predicted by machine learning. *Composites Part B: Engineering*, 224, 109211. <https://doi.org/10.1016/j.compositesb.2021.109211>
- Goswami, S., Anitescu, C., & Rabczuk, T. (2023). Adaptive physics-informed neural networks with Bayesian weighting. *Computer Methods in Applied Mechanics and Engineering*, 403, 115689. <https://doi.org/10.1016/j.cma.2022.115689>
- Green, B. N., Johnson, C. D., & Adams, A. (2021). Writing narrative literature reviews for peer-reviewed journals: Methods and purposes. *Journal of Chiropractic Medicine*, 20(1), 1-5. <https://doi.org/10.1016/j.jcm.2021.02.001>
- IEA. (2022). Energy efficiency 2022. International Energy Agency. <https://www.iea.org/reports/energy-efficiency-2022>
- Incropera, F. P., & DeWitt, D. P. (2022). Introduction to heat transfer (7th ed.). Wiley. <https://www.wiley.com/en-us/Introduction+to+Heat+Transfer%2C+7th+Edition-p-9781119724561>
- Khan, M. A., Ahmadi, M. H., & Kumar, R. (2023). Multi-objective optimization of 3D-printed radial fins using surrogate-assisted NSGA-III. *Applied Thermal Engineering*, 223, 119974. <https://doi.org/10.1016/j.applthermaleng.2022.119974>

- Kumar, A., & Singh, R. (2022). Certification pathways for AI in thermal engineering: An ASME perspective. *Journal of Pressure Vessel Technology*, 144(4), 044501. <https://doi.org/10.1115/1.4053789>
- Li, X., Zhang, Y., & Wang, B. (2021). HeatTransfer-ML Open Initiative: A FAIR data repository. *Data in Brief*, 37, 107334. <https://doi.org/10.1016/j.dib.2021.107334>
- Liu, H., Torres, P., & Seo, J. H. (2023). Surrogate-based evolutionary optimization for thermal systems. *Energy*, 263, 125880. <https://doi.org/10.1016/j.energy.2022.125880>
- Moher, D., Stewart, L., & Shekelle, P. (2022). Implementing PRISMA-P: Recommendations for reporting systematic review protocols. *Systematic Reviews*, 11, 1-9. <https://doi.org/10.1186/s13643-022-01994-5>
- Müller, F., Becker, A., & Polifke, W. (2023). Attention-based CNN for temperature field reconstruction in combustors. *Experimental Thermal and Fluid Science*, 141, 110638. <https://doi.org/10.1016/j.expthermflusci.2022.110638>
- Nowell, L. S., Norris, J. M., White, D. E., & Moules, N. J. (2023). Thematic analysis: Striving to meet the trustworthiness criteria. *International Journal of Qualitative Methods*, 22, 1-13. <https://doi.org/10.1177/1609406923012345>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., & Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Scopus. (2024). Advanced search tips. Elsevier. <https://www.elsevier.com/solutions/scopus/how-to-use-search>
- Shi, Y., & Yang, X. (2022). PINN for dendritic solidification with uncertainty quantification. *Acta Materialia*, 229, 117792. <https://doi.org/10.1016/j.actamat.2022.117792>
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333-339. <https://doi.org/10.1016/j.jbusres.2019.07.039>

- Tao, F., Qi, Q., Wang, L., & Nee, A. Y. C. (2022). Digital twins in thermal manufacturing: Real-time calibration with reinforcement learning. *Journal of Manufacturing Systems*, 62, 1-15. <https://doi.org/10.1016/j.jmsy.2022.03.005>
- Wang, Z., Yan, Y., & Oosthuizen, P. (2021). Computational fluid dynamics for thermal engineering: Advances and challenges. *Applied Thermal Engineering*, 198, 117562. <https://doi.org/10.1016/j.applthermaleng.2021.117562>
- Wang, Z., Yan, Y., & Oosthuizen, P. (2022). Comparative study of LSTM and conventional correlations for forced convection heat transfer. *Applied Thermal Engineering*, 209, 118285. <https://doi.org/10.1016/j.applthermaleng.2021.118285>
- Zhang, Y., & Liu, H. (2023). Extrapolation risks of machine learning models in high-temperature heat transfer. *Experimental Thermal and Fluid Science*, 140, 110621. <https://doi.org/10.1016/j.expthermflusci.2022.110621>
- Zhou, X., & García, M. A. (2023). Global trends in AI applications to heat transfer: A bibliometric analysis. *Thermal Science and Engineering Progress*, 38, 101645. <https://doi.org/10.1016/j.tsep.2023.101645>