

5. Avances en tecnologías de aprendizaje automático e inteligencia artificial para procesos y desastres hidrológicos*



JORGE ALEJANDRO SILVA RODRÍGUEZ DE SAN MIGUEL**

CHRISTIAN MUÑOZ SÁNCHEZ***

DULCE MARÍA MONROY BECERRIL****

DOI: <https://doi.org/10.52501/cc.370.05>

Resumen

El avance del aprendizaje automático y la inteligencia artificial se han convertido en avances tecnológicos pioneros que han transformado el campo de la hidrología, con sus ofertas sin precedentes de herramientas nuevas que se pueden utilizar para modelar procesos hidrológicos complejos y administrar catástrofes hidrológicas. En esta revisión de la literatura, se resumen los avances pertinentes en la IA/ML, aplicaciones relativas a pronóstico de inundaciones, predicción de sequías e hidrología para informar sobre la precisión de predicción, la escala de las aplicaciones y la capacidad de tiempo real del monitoreo de los desarrollos más recientes. Las técnicas emergentes como las arquitecturas de aprendizaje profundo, incluido las redes neuronales recurrentes con unidades (LSTM), las redes neuronales convolucionales (CNN) y otras, modelos de conjunto y marcos híbridos, muestran una mejora significativa en comparación con los modelos hidrológicos tra-

* Derivado del proyecto SIP 20240598: "Responsabilidad social empresarial y sostenibilidad en el abastecimiento de agua".

** Doctor en Ciencias Administrativas. Profesor del Instituto Politécnico Nacional, México. ORCID: <https://orcid.org/0000-0002-0961-4696> ; correo electrónico: jasilva@ipn.mx

*** Doctor en Ciencias Sociales. Profesor-investigador del Instituto Politécnico Nacional, México. ORCID: <https://orcid.org/0000-0001-8692-4252>

**** Doctora en Administración Pública. Profesora-investigadora del Instituto Politécnico Nacional, México. ORCID: <https://orcid.org/0000-0002-0787-5577>

dicionales al conseguir dinámicas no lineales y tiempos significativamente mejorados para la prevención de las intervenciones y medidas de desastre. Además de la integración mejorada de sensores de internet de las cosas (IoT), datos de teledetección y marcos de *big data* para la implementación de monitoreo de tiempo real y sistemas de alerta temprana. La revisión señala brechas críticas, que incluyen la falta de evaluación a largo plazo y la contextualización y falta de escala de implementación de IA. El artículo concluye con recomendaciones para futuras investigaciones que incluyen la exploración de enfoques híbridos, la promoción de plataformas de colaboración intersectorial y la integración de herramientas de IA en marcos políticos y de gobernanza.

Palabras clave: *aprendizaje automático, inteligencia artificial, pronóstico de inundaciones, predicción de sequías, sistemas de alerta temprana.*

Introducción

Los procesos hidrológicos son responsables del movimiento, la distribución y la gestión de los recursos hídricos de la Tierra y son esenciales para mantener los ecosistemas y el sostén de la agricultura y el consumo humano (Yang et al., 2021). Cada uno de estos procesos, a saber, la precipitación, la evaporación, la escorrentía, la infiltración y el flujo de aguas subterráneas, se determina de las condiciones climáticas y factores geográficos. Interrumpir estos procesos puede resultar en inundaciones y sequías, que se conocen a nivel mundial como desastres hidrológicos (Yang et al., 2021). Las inundaciones son uno de los peligros naturales más frecuentes e intensos en el mundo. Cada año, millones de personas se ven afectadas por ellos, y las pérdidas económicas son significativas (Manzoor et al., 2022; Mishra, 2021). Las sequías, en cambio, a menudo surgen más lentamente, pero sus consecuencias a menudo duran años y años. Estos incluyen la disminución de los rendimientos de cultivos, la escasez de agua y la degradación de los ecosistemas (Manzoor et al., 2022; Mishra, 2021).

Como se mencionó anteriormente, la urgencia en la gestión de los procesos hidrológicos está creciendo debido al cambio climático, la alteración

de los patrones de precipitación y la urbanización. Esto exacerba los procesos hidrológicos extremos, incluidas las sequías y las inundaciones repentinas (Xiong y Yang, 2024). Estos cambios, junto con el crecimiento de la población y la expansión urbana, añaden presión a la infraestructura hídrica y aumentan la vulnerabilidad en terrenos inundables y zonas con escasez de agua (Xiong y Yang, 2024). Los marcos de políticas, como el Marco de Sendai para la Reducción del Riesgo de Desastres, hacen hincapié en los sistemas de alerta temprana, las evaluaciones de riesgos y la gestión integrada de los recursos hídricos para abordar este desafío (Xiong y Yang, 2024). Dado que los modelos hidrológicos tradicionales tienen limitaciones significativas en su capacidad para manejar dinámicas complejas y enormes demandas de información, se necesita un enfoque más avanzado, adaptable y basado en datos (Xiong y Yang, 2024).

El ML y la IA proporcionan soluciones innovadoras a dichos desafíos. Al procesar con precisión conjuntos de datos grandes y heterogéneos, como imágenes satelitales y datos de sensores, el ML y la IA son superiores, en términos de precisión predictiva, a los métodos más tradicionales, específicamente a través de técnicas de vanguardia, como el aprendizaje profundo y el ensamble de métodos (Rai et al., 2024). Dichas tecnologías aumentan la previsión de inundaciones en tiempo real, la predicción de sequías y la administración de recursos hídricos condensando flujos de datos en herramientas de toma de decisiones de apoyo para mejorar la administración de desastres y fomentar metas de sostenibilidad globales. Aunque existe un gran potencial, desafíos como la calidad de los datos, la interpretabilidad de los modelos y la implementación en escenarios con escasos recursos dificultan el pleno fructificado de sus beneficios (Rai et al., 2024).

Esta revisión de la literatura contribuye a la consolidación del conocimiento existente sobre ML e IA en hidrología y se enfoca en los avances en previsión de inundaciones, avances en predicción de sequías, y avances en la gestión de cuencas hidrográficas. Además, analiza las tendencias y avances tecnológicos, llama la atención sobre las lagunas de investigación y realiza comparaciones con métodos alternativos, al tiempo que ubica cómo estas metodologías mejoran los enfoques de precisión, seguimiento en tiempo real y toma de decisiones basadas en la gestión del agua estándar. La revisión retoma artículos desde 2019 hasta 2025, mientras que el periodo

que se apropia rápidamente de los avances en IA es marcado por el rebrote y la publicación de estudios que relacionan IA con áreas más afectadas por desastres hidrológicos o áreas ricas en datos como Asia, América del Norte, Europa y África.

Los conceptos básicos de ML e IA, incluido el aprendizaje profundo, las redes neuronales y el modelado basado en datos, son fundamentales para los datos de alta dimensión y la complejidad junto con los modelos hidrológicos tradicionales basados en la física. Dichos modelos abordan procesos hidrológicos que son la precipitación, escorrentía, infiltración y evapotranspiración procesos esenciales para la gestión del agua y la planificación ante desastres. Los fenómenos adversos, inundaciones, sequías y marejadas ciclónicas, aumentan en intensidad y frecuencia debido al cambio climático y la urbanización exigen herramientas con potencial para predecir con anticipación ante la toma de decisiones que mejoren la resiliencia y sostenibilidad.

La revisión se divide en cuatro secciones principales, entre ellas, método, marco teórico y revisión de los hallazgos.

Método

El sistema de revisión sistemática desarrollado para estudiar las aplicaciones de ML e IA en hidrología fue diseñado como exhaustivo y riguroso. La recolección de los estudios fue basada en las guías estándar para revisión sistemática y fue relacionada con bases de datos incluyendo Web of Science, Scopus, IEEE Xplore y Google Scholar como fuente complementaria. Para asegurar la cobertura completa se han utilizado controladores Booleanos y combinaciones de palabras claves incluyendo “machine learning”, “artificial intelligence”, “hydrology”, “flood”, “drought”, “watershed”, “hydrology resources management”. Las cadenas fueron iterativamente refinadas para incluir las variaciones terminológicas, por ejemplo, otras frases como “data-driven modeling” o “flood-risk assessment”. Las publicaciones han sido seleccionadas por lenguaje, que en este caso es inglés, y han sido limitadas hasta 2019-2025: revistas académicas revisadas por pares, capítulos de libros utilizando el mismo año para garantizar su actitud relevante y calidad. Los criterios de elegibilidad enfatizaron la consideración del estudio de todos

los ensayos entre ellos la relevancia tecnológica se implementó llevándola a cabo, así como a adquirir nueva información empírica, diseño de nuevos modelos o reconfiguración de antiguos. Documentos no académicos, que no tienen relevancia y la publicación que no está en inglés fueron excluidos.

El proceso de selección y cribado se compuso de dos etapas. Los títulos y resúmenes fueron revisados en la fase preliminar por dos revisores independientes para incluir estudios que cumplieran con los criterios de inclusión: metodologías de aprendizaje estadístico o inteligencia artificial pertinentes para la hidrología, además de la fecha y el idioma. Las discrepancias entre los revisores se resolvieron mediante discusión o consulta de un tercero. Los artículos que superaron la fase preliminar fueron sometidos a una revisión a texto completo intensiva para confirmar sus narrativas y metodologías. Esta fase excluyó los estudios con metodologías insuficientemente rigurosas o sin datos para su revisión adecuada.

Para garantizar la calidad, la revisión se sirvió de herramientas adicionales como la lista de verificación Prisma 2020 la credibilidad y relevancia de las listas de verificación (CASP), asimismo, como una herramienta de riesgo de sesgo modificada de cuestiones larvadas relacionadas con tamaño de la muestra, la ubicación y disponibilidad de los datos. Los estudios se calificaron en función de la claridad de los objetivos, presentación de los datos y el aprendizaje comparativamente estadístico o de aprendizaje. Los estudios que otras calcularon menos de un umbral predefinido también se marcaron para revisión adicional o exclusión.

Los intentos de atenuar tales sesgos incluyeron la recuperación de literatura de varias bases de datos, a fin de minimizar el sesgo de publicación, verificar las revisiones independientes para reducir el sesgo de selección y el uso de instrumentos adicionales tales como los gráficos en embudo para analizar la variabilidad en los resultados de los estudios. Aunque se desempeñaron de manera dubitativa debido a la variedad de procedimientos metodológicos en los estudios de ML/IA proporcionaron información adicional. Un procedimiento completo y detallado aseguró la recuperación de estudios no tendenciosos y de alta calidad, estableciendo el escenario para la revisión de los avances hídricos en aplicaciones de aprendizaje automático e inteligencia artificial.

Marco teórico

Perspectivas históricas sobre la IA en hidrología

Antes de la generalización de IA, AA en la hidrología, los investigadores primas, modelo basado principalmente en modelos estadísticos y deterministas basados en la física, se aplican para simular y predecir procesos hidrológicos. Los modelos estadísticos se usaban para identificar relaciones lineales entre variables hidrológicas que producían imágenes mientras se usaban para generar junto con índices de sequía en situaciones donde el clima es más estable (Soares y do Carmo Calijuri, 2021; Singh et al., 2023). Por ejemplo, los modelos de regresión-lineal múltiple MLR y de medias móviles integradas autorregresivas EXTI ARIMA se usaron con frecuencia y se diseñaron antes. La regresión del índice de medias móviles lineales desencadenadas en series temporales fue un precursor importante de los métodos de estadística aplicados posteriormente en métodos derivados de datos (Soares y do Carmo Calijuri, 2021; Singh et al., 2023). Por otro lado, los modelos basados en la física determinista buscan representar leyes generalistas que gobiernan los procesos hidrológicos.

Normalmente se aplican para ecuaciones parámetros de calibración diferenciales y ampliadas (Shen et al., 2023). Por mencionar algunos ejemplos, el SWAT (herramienta de evaluación de suelos y aguas), cuyos datos se obtienen con precisión espacial y se emplean para prever los efectos del uso del suelo y las alteraciones en el clima en tres componentes de balance hídrico (Shen et al., 2023; Nascimento, 2020). Con cuerpos hídricos en escala de cuencas y velocidad del agua un HEC-HMS (sistema de modelado hidrológico).

Si bien estos modelos son expertos en la representación de procesos, a menudo presentan limitaciones en cuanto a disponibilidad de datos, incertidumbre de los parámetros y complejidad computacional, especialmente cuando se trata de simular cuencas más grandes o escasas en datos (Shen et al., 2023; Nascimento, 2020). Estos desafíos favorecieron la generación y el impulso de modelos alternativos y más flexibles a principios de los modelos de la RNA fueron el resultado de los primeros intentos de expresar tales

relaciones no lineales inherentes a las series temporales hidrológicas (Shen et al., 2023; Nascimento, 2020).

Dichas aplicaciones supusieron una desviación de las restricciones y suposiciones rígidas en la línea y distribuciones de parámetros, siendo reemplazadas por el aprendizaje en base a datos observados para generar patrones (Guan et al., 2020). Esta tendencia marcó una ruptura drástica desde el paradigma convencional y forzó a los investigadores hidrológicos a explorar las capacidades de la CI para resolver los fenómenos hidrológicos que abarcaron sobre las múltiples escalas (Guan et al., 2020). Esto hizo que se aplicara este espectro de IA/ML para técnicas de modelación hidrológica. Por ejemplo, la lógica difusa trató con incertidumbre e imprecisión notables en la relación entre la lluvia y la escorrentía, y los algoritmos genéticos proporcionaron enfoques de búsqueda y optimización para la calibración del modelo (Yaseen, 2023). Con el tiempo, estas técnicas evolucionaron aún más y dieron lugar a arquitecturas de aprendizaje profundo como CNN, RNA con partes LSTM que podían abordar conjuntos de datos voluminosos, incluidos las entradas características de las operaciones de teledetección y los datos de sensor en tiempo real (Yaseen, 2023).

Varias razones respaldaron este cambio hacia el modelado basado en datos: los avances computacionales, como el auge de la computación de alto rendimiento y las plataformas en la nube, que redujeron los tiempos de entrenamiento para modelos computacionalmente intensivos; la creciente disponibilidad de datos, como la proliferación de imágenes satelitales, redes de sensores terrestres y bases de datos climáticas de acceso abierto, que proporcionaron datos ricos y heterogéneos para alimentar modelos de IA más complejos; y la mayor sofisticación de los modelos, a saber, la aparición de nuevos marcos de aprendizaje automático, como las redes neuronales profundas, que ofrecieron un mejor rendimiento en la captura de los procesos hidrológicos intrincados y no lineales en comparación con la regresión tradicional o las redes Neuronales Artificiales (ANN) simples (Guan et al., 2020; Khan y Zakarya, 2021).

A medida que estos métodos maduraron, surgieron modelos híbridos más sofisticados que combinaban el conocimiento del dominio con las formulaciones basadas en el aprendizaje profundo. Estos enfoques combinaban la flexibilidad y la eficiencia predictiva integral de la IA con una sólida base

de conocimiento físico dentro de un sólo marco, lo que les permitió superar en muchos aspectos tanto a la IA pura como a los enfoques basados en la física. Hoy en día, los investigadores continúan perfeccionando y ampliando estos enfoques, aprovechando los avances en IA explicable y cuantificación de la incertidumbre (Kouraytem et al., 2021; Wang et al., 2022).

Principales académicos, grupos de investigación y escuelas de pensamiento

En síntesis, una red global de investigadores e instituciones ha contribuido a hacer avanzar la Inteligencia Artificial en hidrología, innovar tanto en la teoría como en la aplicación y fomentar la colaboración en el trabajo. Los pioneros innovadores, como Soroosh Sorooshian de la Universidad de California, Irvine, presentaron por primera vez modelos puramente basados en datos para la gestión de recursos hídricos aquí; UPmanu Lall de la Universidad de Columbia avanzó la competencia de aprendizaje automático en gestión de riesgos hídricos y previsión hidrológica; y Vijay P. Singh de la Universidad Texas A&M introdujo enfoques de IA híbrida en la dinámica de las cuencas hidrográficas; mientras que ZM Yaseen se centró en el aprendizaje profundo en la predicción de inundaciones y sequías, haciendo énfasis en el rendimiento y la interpretabilidad.

Además, la integración de la IA con la teledetección y el *big data* para la hidrología de regiones frías y el monitoreo a gran escala también es un enfoque pionero en el Instituto Global para la Seguridad del Agua de la Universidad de Saskatchewan y el Centro de Vuelos Espaciales Goddard de la NASA. Para la previsión basada en la red, los liderazgos europeos, como HEPEx, y las organizaciones, como Deltares y ETH Zurich, se han adelantado con herramientas mejoradas por IA. Además, instituciones como la UNESCO, el Programa Internacional de la Geosfera y la Biosfera (IGBP) y el Programa Mundial de Investigación de Clima (WCRP) han estado fomentando proyectos relacionados con IA interdisciplinarios para la modelación fluvial CC. De los modelos estadísticos hidráulicos estáticos a los marcos de IA dinámicos, se han creado instrumentos innovadores para la gestión de de-

sastres y recursos hídricos y aplicaciones al consumidor, y así poder llevar los marcos de políticas.

Debates o controversias en curso

Confiabilidad del modelo frente a interpretabilidad

Uno de los debates más destacados en la hidrología basada en IA dice relación con la compensación entre la confiabilidad y la interpretabilidad del modelo (Hassija et al., 2024; Ivanovs et al., 2021). En general, los modelos de *black box*, que incluyen en particular las redes neuronales profundas, a menudo logran un rendimiento predictivo sorprendente al capturar relaciones complejas y no lineales que pueden pasar desapercibidas por enfoques más simples y tradicionales impulsados por datos (Hassija et al., 2024; Ivanovs et al., 2021). Sin embargo, estos modelos avanzados carecen de explicaciones simples de cómo los insumos se convierten en resultados, lo que plantea preocupaciones sobre su transparencia y confiabilidad para ser utilizados en la gestión de recursos hídricos (Hassija et al., 2024; Ivanovs et al., 2021). La interpretabilidad es esencial en situaciones de política y gobernanza pública y el compromiso de las partes interesadas, ya que los tomadores de decisiones enfrentan la tarea de razonar claramente y justificar sus esfuerzos para intervenir en situaciones de inundaciones, sequías, y similares (Hassija et al., 2024; Ivanovs et al., 2021).

En un intento por mitigar esta preocupación, algunos investigadores han propuesto técnicas de IA explicables como mapas de saliencia, medidas de importancia de características y explicaciones locales interpretables independientes del modelo (Hassija et al., 2024; Ivanovs et al., 2021). No obstante, otros mantienen que el requerir total interpretabilidad puede comprometer el rendimiento predictivo de los modelos de IA, sugiriendo que los enfoques híbridos ofrecen el mejor equilibrio entre confiabilidad y claridad (Hassija et al., 2024; Ivanovs et al., 2021). En resumen, subyace una controversia fundamental: ¿cuánta opacidad es aceptable en la mecánica del modelo, si su confiabilidad mejorada puede radicalmente mejorar las evaluaciones de riesgos y planificación de recursos?

Calidad y disponibilidad de los datos

Los modelos de IA para la hidrología requieren amplios conjuntos de datos de alta calidad para el entrenamiento y la validación. A pesar de esto, la escasez de datos, los errores en las mediciones y las redes de sensores erráticas siguen siendo desafíos significativos globales (Kebede et al., 2024; Şen, 2021). En muchos lugares en desarrollo, la falta de infraestructura hidrometeorológica sólida da como resultado registros incompletos o poco fiables, sofocando los progresos en soluciones de ML de vanguardia. Los desafíos aún persisten incluso en países desarrollados, ya sea por formatos de datos dispersos y patentados que interrumpen un acceso abierto (Kebede et al., 2024; Şen, 2021).

Se añade un nivel adicional de controversia con los datos parciales, a menudo con errores humanos, como la representación desigual e insuficiente de los regímenes hidroclimáticos o los años de salida. Los modelos entrenados en datos sesgados emiten pronósticos sesgados porque no se ajustan lo suficiente para capturar la verdadera variabilidad de los procesos hidrológicos; no pueden generalizarse a través de las cuencas (Kebede et al., 2024; Şen, 2021).

Al mismo tiempo, las imágenes de satélites de alta resolución y las redes de sensores de IoT llenan los vacíos de los datos, también introducen calibración y desafíos de integración. Con todo, los investigadores discuten si el aumento de datos *ad hoc* o los enfoques de aprendizaje por transferencia puede vencer suficientemente las limitaciones de los datos o si las inversiones son demasiado importantes en mediciones de campo y verificación de campo (Kebede et al., 2024; Şen, 2021).

Consideraciones éticas y políticas

A medida que las aplicaciones de IA en hidrología se vuelven más sofisticadas y potencialmente automatizadas, las dimensiones éticas y políticas se vuelven cada vez más importantes (Aldahlawi et al., 2024; Chitwatkulsiri y Miyamoto, 2023). Por ejemplo, las predicciones algorítmicas podrían cambiar drásticamente la asignación de agua, la planificación urbana o las es-

trategias de evacuación en caso de inundación, lo que plantea preguntas sobre la justicia, la equidad y la responsabilidad en la toma de decisiones (Aldahlawi et al., 2024; Chitwatkulsiri y Miyamoto, 2023).

Los posibles sesgos dentro de los modelos de IA, derivados de un muestreo de datos inadecuado o suposiciones del modelo, podrían poner en peligro a las comunidades marginadas o subrepresentadas en regiones propensas a inundaciones o con escasez de agua (Aldahlawi et al., 2024; Chitwatkulsiri y Miyamoto, 2023). Además, los marcos de políticas en muchos países no han seguido el ritmo de las rápidas innovaciones de la IA. Esta brecha genera incertidumbre en cuanto a la gobernanza de los datos, los derechos de propiedad intelectual para las herramientas hidrológicas impulsadas por la IA y la responsabilidad cuando las decisiones basadas en modelos genéticos producen patrones subóptimos o perjudiciales (Aldahlawi et al., 2024; Chitwatkulsiri y Miyamoto, 2023).

Revisión de los hallazgos

Algoritmos de aprendizaje automático

Las redes neuronales se han convertido en uno de los pilares clave en la aplicación de la IA a los procesos hidrológicos, desconocidos en la facultad de aprender relaciones complejas y no lineales de grandes conjuntos de datos (Lee, 2024; Mishra et al., 2022). La primera se basó en el uso de perceptrones multicapa para el modelado de lluvia y escorrentía. Las novedades más recientes se enfocan en redes neuronales profundas, aprovechando algoritmos de aprendizaje automático para extraer patrones multiescala (Lee, 2024; Mishra et al., 2022).

En el ámbito de la arquitectura profunda, las redes de convolución CNN se han revelado efectivas para explotar las dependencias espaciales, fomentando la integración de imágenes de teledetección, modelos digitales de elevación y clasificaciones de uso de la tierra (Lee, 2024; Mishra et al., 2022). Por otra parte, en los casos de pronóstico de series temporales, como los caudalpredicciones o las inundaciones, las Redes Neuronales de

Memoria a Corto y Largo Plazo LSTM han surgido en calidad de alternativa (Lee, 2024; Mishra et al., 2022).

Más allá del marco del aprendizaje profundo, las técnicas de ensamble, como RF, GB y XGBoost, han demostrado un sólido desempeño en tareas de clasificación y regresión. La adopción de estos algoritmos combina múltiples aprendices débiles, p. ej., árboles de decisión, siendo eficientes para reducir la varianza y fortalecer la generalización de los resultados (Lee, 2024; Mishra et al., 2022). En varios casos, los enfoques híbridos o novedosos asisten para la resolución, p. ej., sistemas neurodifusos, combinando las características de las redes neuronales y las oportunidades de la lógica difusa (Lee, 2024; Mishra et al., 2022).

También, los investigadores experimentan con el aprendizaje por transferencia, entrenando modelos preentrenados de una cuenca o región climática en otra que adolece de datos de observación (Lee, 2024; Mishra et al., 2022). Investigaciones de vanguardia sugieren que los enfoques híbridos de aprendizaje automático y físico pueden cerrar aún más la brecha entre la interpretabilidad y la precisión predictiva a través de la integración del conocimiento del dominio en arquitecturas de IA avanzadas (Lee, 2024; Mishra et al., 2022).

Asimismo, el aprendizaje por refuerzo se experimenta entre las direcciones potenciales de desarrollo, adaptando las operaciones de los embalses y las estrategias de asignación de agua y permitiendo que los agentes de IA aprendan a igualar demandas de agua en competencia con un clima inestable (Lee, 2024; Mishra et al., 2022). Las redes neuronales generativas antagónicas se utilizan para sintetizar o aumentar los datos hidrológicos, p. ej., patrones de precipitaciones simuladas o cumplimentación de sensores faltantes (Lee, 2024; Mishra et al., 2022). Estas innovaciones sirven de manifestación concreta de la voluntad constante de los investigadores de desarrollar soluciones flexibles y adaptativas que pueden enfrentarse al desafío de la incertidumbre inherente en el campo de los sistemas hidrológicos (Lee, 2024; Mishra et al., 2022).

Big data y herramientas computacionales

A medida que se incrementan los volúmenes de datos hidrológicos y climáticos debido a las mejoras en la teledetección, las redes de sensores y las plataformas de modelación, las infraestructuras basadas en la nube y HPC se han vuelto esenciales (Mittal y Vaishay, 2019; Shuvo e Islam, 2022).

Plataformas como Amazon Web Services y Microsoft Azure proporcionan recursos computacionales elásticos para procesar instantáneamente conjuntos de datos a escala de terabytes. High-Performance Clusters y Graphics Processing Units reducen drásticamente los tiempos de entrenamiento para modelos de aprendizaje profundo, lo que facilita la optimización de los hiperparámetros y las simulaciones en conjuntos que antes no eran factibles (Mittal y Vaishay, 2019; Shuvo e Islam, 2022).

La contenedorización y los sistemas de gestión de flujos de trabajo estandarizan y automatizan la implementación del modelo para promover una experimentación más rápida y la reproducibilidad (Mittal y Vaishay, 2019; Shuvo e Islam, 2022). Para el análisis espacial, Google Earth Engine, ArcGIS y QGIS *plug-ins* se integran extensamente con bibliotecas de ML para acelerar el pipeline de ingestión y preprocesamiento de grandes conjuntos hidrológicos (Mittal y Vaishay, 2019; Shuvo e Islam, 2022). Estas herramientas facilitan las evaluaciones a múltiples escalas fusionando imágenes satelitales, imágenes satelitales, datos topográficos y productos de reanálisis climático.

La sinergia entre las plataformas geoespaciales y la computación en la nube permite continuidades minimizando manualidad que es crítica para pronósticos operativos o sistemas de monitoreo que requieren actualizaciones (Mittal y Vaishay, 2019; Shuvo e Islam, 2022). A pesar del *hardware* y del *software* avanzados, el preprocesamiento de datos sigue siendo un cuello de botella crítico. La heterogeneidad de las fuentes, como los resultados satelitales, *in situ* y modelos, a menudo resulta en discrepancias importantes en la resolución espacial, temporal y en los formatos de archivo (Mittal y Vaishay, 2019; Shuvo e Islam, 2022).

Mientras las técnicas como el escalado de características, reducción de dimensionalidad y la interpolación espaciotemporal se emplean rutinariamente, estos pueden imponer sumas de incertidumbre insatisfactorias (Mi-

ttal y Vaishay, 2019; Shuvo e Islam, 2022). Los controles de calidad, la detección de valores atípicos, corrección de errores del sensor, llenado de brechas, por ejemplo, puede consumir grandes recursos lo cual impulsa la demanda de conjuntos abiertos normalizados y algoritmos de limpieza automatizados (Mittal y Vaishay, 2019; Shuvo e Islam, 2022).

Habiendo abordado estos desafíos y maximizado el potencial de los entornos *big data*, el modelo se mantiene tal cual, y los métodos críticos siguen siendo utilizables en aplicaciones con alto costo de misión como la alerta temprana de inundaciones o administración de riesgo de sequía (Mittal y Vaishay, 2019; Shuvo e Islam, 2022).

Principales hallazgos en el desempeño y precisión predictiva

Previsión de inundaciones

La aplicación más importante del ML y la IA en hidrología es la previsión de inundaciones. La razón es que hacer un modelo predictivo preciso y atemporal puede reducir significativamente los daños a la propiedad y las muertes (Kumar et al., 2023; Li et al., 2024).

Las arquitecturas de datos como las LSTM, y CNN han demostrado una mejor captura de la dinámica compleja y no lineal de los eventos de inundación en comparación con los modelos hidrológicos tradicionales (Kumar et al., 2023; Li et al., 2024). Específicamente, los enfoques LSTM pueden capturar dependencias de largo alcance en los datos de lluvia y escorrentía, mejorando así los tiempos de entrega y la confiabilidad de los pronósticos de inundaciones repentinas e inundaciones fluviales (Kumar et al., 2023; Li et al., 2024).

Además, las técnicas de conjunto han funcionado bien en la manipulación de la entrada de datos de alta dimensión y reducción de la varianza predictiva (Kumar et al., 2023; Li et al., 2024). En estudios intercomprometidos, estos modelos de conjunto son lo suficientemente generales como para superar estadísticamente los modelos independientes y los modelos de redes neuronales simples en una variedad de regiones hidroclimáticas (Kumar et al., 2023; Li et al., 2024). La precisión mejorada se traduce en

alertas de inundaciones más rápidas, lo que da a las autoridades locales tiempo suficiente para comenzar a evacuar y restringir los recursos (Kumar et al., 2023; Li et al., 2024). Aunque estos son éxitos, hay algunas trampas, la generalización de un modelo en cuencas con datos limitados, sobrecarga de ajuste de hiperparámetros computacionales y dificultades de la caja negra son áreas activas en la investigación (Kumar et al., 2023; Li et al., 2024).

Sequía y gestión de los recursos hídricos

Además de las previsiones de inundaciones, los pronósticos de sequía han sido enormemente mejorados por las técnicas ML/IA avanzadas, particularmente en áreas donde la planificación a largo plazo del uso del agua es clave (Ahmed et al., 2024; Sundararajan et al., 2021).

Los modelos que usan análisis de series de tiempo, a menudo combinando datos de teledetección p.ej. Índices de vegetación de satélites con datos meteorológicos, pueden identificar precursores de déficit de lluvia, tensión en el sistema alimentario y agotamiento de los depósitos subterráneos (Ahmed et al., 2024; Sundararajan et al., 2021).

En este escenario, los métodos ML como la regresión de vectores de soporte y bosques aleatorios generalmente producen predicciones más precisas de los índices de sequía estandarizados que la regresión lineal o enfoques meramente físicos (Ahmed et al., 2024; Sundararajan et al., 2021).

Para el monitoreo de las aguas subterráneas, los investigadores han implementado modelos de aprendizaje profundo y de conjunto para prever los niveles del agua subterránea en una variedad de escenarios climáticos y de bombeo, lo que resulta en información sobre la tasa de extracción sostenible (Ahmed et al., 2024; Sundararajan et al., 2021).

Además, la combinación de modelos de aprendizaje automático con información hidrogeológica y *land-use* nuevos e incluso mejorados también mejora la identificación de los puntos flacos de la sobreexplotación, alimentando decisiones políticas y mecanismos de asignación de retorno (Ahmed et al., 2024; Sundararajan et al., 2021).

Sistemas de vigilancia en tiempo real y alerta temprana

Cada vez más publicaciones destacan el papel del monitoreo en tiempo real en el fortalecimiento de los Sistemas de Alerta Temprana (SAT) para inundaciones, sequía y otros desastres hidrológicos (Perera et al., 2019). La reciente aparición de los sensores de internet de las cosas (IdC) —midiendo las precipitaciones, la humedad del suelo, los niveles de agua y calidad del agua— permite una recopilación de datos continua y de alta frecuencia cuando se combinan con algoritmos de detección de anomalías, basado en aprendizaje automático plataformas DSS de SAT, pueden descubrir anomalías, como los rápidos aumentos en los niveles de agua o la repentina caída de humedad del suelo (Perera et al., 2019).

Destacan, además, la teledetección tecnologías, especialmente SAR y satélites ópticos, para un mapeo casi en tiempo real de la extensión de la inundación que se utiliza para asimilar la predicción del modelo de la inundación en conjuntos de datos y actualizaciones sobre un tiempo base dinámico (Schumann et al., 2023).

La asimilación dinámica de datos de sensores e imágenes de satélite ha reducido significativamente el tiempo de cero a una respuesta por agencias de gestión de desastres (Schumann et al., 2023). Existen también entornos de computación en la nube, la Tierra de Google (EE), AWS, que permiten una computación en tiempo real, oportunidades de revestimientos exactos para los terabytes de señales entrantes de alto flujo, la detección de escala, la medición satelital de inundaciones (Schumann et al., 2023).

Los cálculos y los primeros instantáneos, y la administración son de vital importancia para las alertas tempranas protocolos, especialmente en sincronía ha inundaciones inestables o acceso a rápidamente (Zulfaqar et al., 2024). El desafío actual para lanzar estas evaluaciones en tiempo real a gran escala efectiva siga siendo los costos de la infraestructura (Zulfaqar et al., 2024).

La fiabilidad de tiempo real SAT es redundancia de la red. Las protuberancias, las violaciones de los sensores o la comunicación han interrumpido los pronósticos actuales que los hacen confiables (Zulfaqar et al., 2024).

Tendencias emergentes, innovaciones y debates

Integración de datos en tiempo real e IoT

La convergencia de la red de sensores, los datos de teledetección y el análisis de inteligencia artificial ha surgido una nueva era de monitoreo hidrológico en tiempo real. Los dispositivos de internet de las cosas, que varían desde sensores terrestres que miden el nivel del agua y la humedad del suelo hasta generadores de imágenes basados en drones para evaluar las condiciones de las llanuras aluviales, producen datos de alta frecuencia a ser estudiados y visualizados en el momento (Rahman et al., 2023).

Esta amplia cantidad de información en tiempo real mejora la granularidad y la puntualidad de los conocimientos hidrológicos, permitiendo a las autoridades un *feedback* casi instantáneo de los cambios en su entorno ambiental (Rahman et al., 2023). En la práctica, varias plataformas basadas en la nube usan datos IoT combinados con datos de teledetección para disciplinar canales de aprendizaje automático para detectar inundaciones, evaluar sequías y prever flujos de ríos (Rahman et al., 2023).

La data en tiempo real combinada ayuda a detectar anomalías mediante métodos de aprendizaje automático de detección de anomalías, como aumentos repentinos en el nivel del agua o cambios abruptos en la profundidad del agua subterránea (Rao, 2022).

El resultado es un sistema de alerta temprana más dinámico y reactivo, el cual puede ajustar modelos predictivos en base a observaciones nuevas, reduciendo el riesgo a sorpresas catastróficas (Lakshmanna, 2022). Sin embargo, a pesar del atractivo de estos enfoques unificados, enfrentan barreras técnicas e institucionales, como la seguridad de la red, los acuerdos de “sharing” de datos y los altos costos de equipar infraestructuras extensivas de sensores (Lakshmanna, 2022).

IA explicable en hidrología

A medida que los modelos de aprendizaje automático se vuelven más complejos, las preguntas relacionadas con la aplicabilidad y la transparencia se han vuelto más prominentes (Asif, 2024).

Muchos modelos de aprendizaje profundo actuaban como “cajas negras” que ocultaban cómo los datos de entrada se traducían en resultados. Esta opacidad puede socavar la confianza, en el peor de los casos, disminuir su confianza en tales modelos (Asif, 2024).

En respuesta, ha surgido un interés creciente en los métodos de inteligencia artificial explicables dentro de la hidrología, como las métricas de importancia de características, el mapeo de saliencia, la propagación de relevancia por capas (LRP) y las explicaciones locales interpretables del modelo (Muhammad y Bendeckache, 2024).

Estas técnicas buscan visualizar o cuantificar el impacto de las variables de entrada en las predicciones del modelo, aumentando la transparencia y, por ende, la confianza del usuario (Muhammad y Bendeckache, 2024). En paralelo, ha habido desarrollos de modelos híbridos de *ever-ML*-físicos, que incorporan el conocimiento del dominio en marcos de inteligencia artificial para producir (Muhammad y Bendeckache, 2024). Aunque sigue siendo un frente de investigación activo, estos enfoques explicables prometen equilibrar la capacidad predictiva con la necesaria responsabilidad requerida por *end-users* como los ingenieros y los legisladores (Muhammad y Bendeckache, 2024).

Colaboración interdisciplinaria

La complejidad de la gestión de los recursos hídricos, en términos meteorológicos, ecológicos, sociales y económicos, necesita alianzas de cantarranas entre científicos informáticos, hidrólogos y reguladores políticos (Fu et al., 2024). Los consorcios de colaboración, como el Instituto Global para la Seguridad del Agua y HEPEX (Experimento de Predicción de Conjuntos Hidrológicos), ofrecen ejemplos de cómo la subsanación de las

divisiones disciplinares acelera la innovación y el despliegue operativo de IA en hidrología (Fu et al., 2024).

Los científicos informáticos aportan unos algoritmos de concepción, informática paralela y estructuras de datos, y los hidrólogos aportan su pericia específica del campo, garantizando que las encarnaciones del modelo comprendan los procesos físicos inherentes (Fu et al., 2024). En el ínterin, los administradores políticos y del agua aportan una perspectiva sobre las restricciones regulatorias y las probabilidades de adhesión pública, las cuales guían la evasión de los resultados de IA en medidas emprendedoras (Fu et al., 2024).

Se han hecho progresos significativos en la apertura de datos y repositorios compartidos los cuales permiten la colaboración en la investigación y la comparación de los modelos globales entre sí (Fu et al., 2024). Sin embargo, siguen existiendo preocupaciones por la financiación, las estructuras organizacionales y los silos disciplinarios (Fu et al., 2024).

Los investigadores y los profesionales subrayan la desesperación de la formación de más máquinas multidisciplinarios que combinen no sólo la ciencia medioambiental con la ciencia informática, sino también la investigación social y la supervisión ética (Fu et al., 2024).

La colaboración exhaustiva mejora las probabilidades de erradicar las reparaciones de IA desde los experimentos de práctica hasta la emulación generalizada, incrementando así el número de resistencia a los desafíos climatológicos del agua (Fu et al., 2024).

Análisis comparativo de estudios

Fortalezas y limitaciones

Una de tales fortalezas, pero no la última, es la heterogeneidad de los algoritmos empleados; desde modelos de ML poco profundos, como SVR y RF, hasta arquitecturas profundas, como LSTM, CNN y redes de transformadores, que han llevado a una fuerte predicción en los campos de la predicción de inundaciones y la evaluación de la sequía durante la última década (Fu et al., 2024).

Así, la adopción de paradigmas de *big data*, en términos de teledetección de alta resolución y IoT-sensores, subraya la ventaja competitiva de la IA hidrológica actual (Fu et al., 2024). Además, algunos grupos de investigación están demostrando marcos integrados o híbridos que mecánicamente incorporan restricciones físicas en los modelos de ML, lo que minimiza el peligro de correlaciones espurias y aumenta la interpretación de la salida (Fu et al., 2024).

Pero todas las esperanzas de revolución también se ven obstaculizadas en varios impedimentos. La calidad de las entradas aún es un impedimento mayor; la mayoría de las cuencas faltan registros a largo plazo y de alta frecuencia o pierden una breve cobertura de salida. Esto conduce a un sesgo de modelo para áreas bien instrumentadas (Fu et al., 2024).

El sobreajuste es un problema extra, ya que “los modelos, particularmente los modelos de *deep learning*, manifiestan un rendimiento excelente en los conjuntos de datos de formación, pero demuestran que no se puede generalizar para diferentes entornos” (Fu et al., 2024, p. 14507). Además, en entornos con recursos limitados, la intensidad computacional también puede ser un desafío, ya que el entrenamiento de modelos complejos y el manejo de grandes conjuntos de datos requieren una estructura informática significativa (Fu et al., 2024). Finalmente, sigue habiendo un debate abierto sobre la naturaleza de caja negra de muchos enfoques de IA de vanguardia, lo que impulsa la necesidad de soluciones de IA más robustas desde el punto de vista de la IA transparente (Fu et al., 2024).

Factores contextuales

Las condiciones geográficas, climáticas y socioeconómicas son críticas para la eficacia y la aplicabilidad de los modelos hidrológicos basados en datos, según Fu et al. (2024). Por ejemplo, para las regiones tropicales, “la alta variabilidad espaciotemporal de la precipitación, que en muchos casos sólo puede abordarse a través de redes de sensores de alta resolución o productos satelitales incluso para los algoritmos de aprendizaje automático más sofisticados” puede ser un desafío (Fu et al., 2024, p. 14515); mientras que las cuencas áridas y semiáridas pueden padecer escasez de

datos; por lo tanto: la calibración y validación de los modelos es más complicada incluso con la transferencia de aprendizaje o adaptación de dominio” (Fu et al., 2024, p. 14527).

Señalan Fu et al. (2024) que, además, las varias variables sociodemográficas también afectan la implementación de soluciones de IA. Por ejemplo, incluso si las alertas de inundaciones en tiempo real no tienen un efecto diferenciado, podría tener un éxito limitado en lugares con mecanismos de respuesta a emergencias subdesarrollados. Además, la aceptación cultural y social —o la percepción y la confianza por parte de los interesados— influye en la manera en que se implementan las soluciones de IA (Chiloane et al., 2022). Es más probable que los trabajos que incorporan los “conocimientos” tradicionales o que son apoyadas por la participación de la comunidad tengan niveles más altos de adopción de sistemas de predicción y planificación del agua (Chiloane et al., 2022). Estos matices contextuales enfatizan que, aunque los marcos de IA sean inevitablemente necesarios, las mejoras y la equidad en la gestión del agua se basarán en su adaptación a las condiciones hidrológicas y los antecedentes institucionales regionales (Chiloane et al., 2022).

Conclusión

La IA y el AA han cambiado radicalmente la forma en que los fenómenos hidrológicos se monitorean, modelan y predicen. Esta innovación se ha reflejado en la precisión mejorada de las predicciones de los algoritmos de AA superficial y las arquitecturas de aprendizaje profundo, como las LSTM y las CNN, especialmente para pronósticos no lineales y de alta dimensión.

Los sistemas de predicción en tiempo real de inundaciones y sequías y el monitoreo y la gestión de embalses se han visto notablemente mejorados, impulsados por la combinación con *big data*, la computación en la nube y las infraestructuras informáticas de alto rendimiento.

La oportuna toma de decisiones a través de sistemas y modelos de alerta temprana e integrados ha estado habilitada por estos avances para apoyar la reducción del riesgo de desastres y la gestión del agua. Los avances en el aprendizaje por transferencia, e IA por refuerzo, han coincidido

con la escasez de datos y la optimización de los sistemas de recursos hídricos. Las iniciativas de IA también han contribuido a marcos internacionales como el Marco de Sendai y el Objetivo de Desarrollo Sostenible 6, al aumentar la resiliencia a los desastres hidrológicos. Sin embargo, existen varios desafíos por abordar. En primer lugar, la fiabilidad de los modelos de IA se ve obstaculizada por desafíos en los datos, que incluyen la escasez, la inconsistencia, las principales restricciones de propiedad y las regiones en desarrollo. La segunda es la interpretación de modelos, en la cual muchos aprendizajes de IA de caja negra disminuyen la confiabilidad de sus usuarios. Aunque los marcos XAI y la combinación de elementos físicos y de IA se ven prometedores.

Otros desafíos incluyen la transferibilidad de AI a otras regiones debido al clima y las diferencias socioeconómicas y falta de validación a largo plazo en tiempo futuro. Se necesitan más colaboraciones entre disciplinas y entre personas para abordar estos problemas: acciones en profundidad para abordar los desafíos y la necesidad de un mayor desarrollo híbrido. Es menester también la continuidad de XAI para aplicaciones hidrológicas y otras herramientas de colaboración interdisciplinarias y protocolos unificados para actividades vinculantes mediante asociaciones e incentivos de financiación. Es fundamental integrar la IA con el marco de gestión para garantizar un esfuerzo sistémico y ético.

Referencias

- Ahmed, A. A., Sayed, S., Abdoulhalik, A., Moutari, S. y Oyedele, L. (2024). Applications of machine learning to water resources management: A review of present status and future opportunities. *Journal of Cleaner Production*, 441, 140715. <https://doi.org/10.1016/j.jclepro.2024.140715>
- Aldahlawi, R. Y., Akbari, V. y Lawson, G. (2024). A systematic review of methodologies for human behavior modelling and routing optimization in large-scale evacuation planning. *Journal of Cleaner Production*, 110, 104638. <https://doi.org/10.1016/j.jij-drr.2024.104638>
- Asif, M. (2024). *Deep learning: Unraveling the black box of neural networks* (Preprint 12535). EasyChair.
- Chatrabhuj, Meshram, K., Mishra, U. y Omar, P. J. (2024). Integration of remote sensing

- data and GIS technologies in river management system. *Discover Geoscience*, 2(1), 67. <https://doi.org/10.1007/s44288-024-00080-8>
- Chang, F. J., Chang, L. C. y Chen, J. F. (2023). Artificial intelligence techniques in hydrology and water resources management. *Water*, 15(10). <https://doi.org/10.3390/w15101846>
- Chiloane, C., Dube, T. y Shoko, C. (2022). Impacts of groundwater and climate variability on terrestrial groundwater dependent ecosystems: A review of geospatial assessment approaches and challenges and possible future research directions. *Geocarto International*, 37(23), 6755-6779. <https://doi.org/10.1080/10106049.2021.1948108>
- Chitwatkulsiri, D. y Miyamoto, H. (2023). Real-time urban flood forecasting systems for Southeast Asia: A review of present modelling and its future prospects. *Water*, 15(1), 178. <https://doi.org/10.3390/w15010178>
- Fu, X., Jiang, J., Wu, X., Huang, L., Han, R., Li, K., ... y Wang, Z. (2024). Deep learning in water protection of resources, environment, and ecology: Achievement and challenges. *Environmental Science and Pollution Research*, 31(10), 14503-14536. <https://doi.org/10.1007/s11356-024-31963-5>
- Guan, C., Mou, J. y Jiang, Z. (2020). Artificial intelligence innovation in education: A twenty-year data-driven historical analysis. *International Journal of Innovation Studies*, 4(4), 134-147. <https://doi.org/10.1016/j.ijis.2020.09.001>
- Hassija, V., Chamola, V., Mahapatra, A., Singal, A., Goel, D., Huang, K., ... y Hussain, A. (2024). Interpreting black-box models: A review on explainable artificial intelligence. *Cognitive Computation*, 16(1), 45-74. <https://doi.org/10.1007/s12559-023-10179-8>
- Ibrahim, K. S. M. H., Huang, Y. F., Ahmed, A. N., Koo, C. H. y El-Shafie, A. (2022). A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting. *Alexandria Engineering Journal*, 61(1), 279-303. <https://doi.org/10.1016/j.aej.2021.04.100>
- Ivanovs, M., Kadikis, R. y Ozols, K. (2021). Perturbation-based methods for explaining deep neural networks: A survey. *Pattern Recognition Letters*, 150, 228-234. <https://doi.org/10.1016/j.patrec.2021.06.030>
- Kamyab, H., Khademi, T., Chelliapan, S., Saberikamarposhti, M., Rezaia, S. yusuf, M., ... y Ahn, Y. (2023). The latest innovative avenues for the utilization of artificial intelligence and big data analytics in water resource management. *Results in Engineering*, 20, 101566. <https://doi.org/10.1016/j.rineng.2023.101566>
- Kebede, E. A., Abou Ali, H., Clavelle, T., Froehlich, H. E., Gephart, J. A., Hartman, S., ... y Davis, K. F. (2024). Assessing and addressing the global state of food production data scarcity. *Nature Reviews Earth & Environment*, 5(4), 295-311. <https://doi.org/10.1038/s43017-024-00516-2>
- Khan, A. A. y Zakarya, M. (2021). Energy, performance and cost-efficient cloud data centers: A survey. *Computer Science Review*, 40, 100390. <https://doi.org/10.1016/j.cosrev.2021.100390>
- Kim, T. yang, T., Gao, S., Zhang, L., Ding, Z., Wen, X., ... y Hong, Y. (2021). Can artificial intelligence and data-driven machine learning models match or even replace pro-

- cess-driven hydrologic models for streamflow simulation?: A case study of four watersheds with different hydro-climatic regions across the CONUS. *Journal of Hydrology*, 598, 126423. <https://doi.org/10.1016/j.jhydrol.2021.126423>
- Kouraytem, N., Li, X., Tan, W., Kappes, B. y Spear, A. D. (2021). Modeling process-structure-property relationships in metal additive manufacturing: A review on physics-driven versus data-driven approaches. *Journal of Physics: Materials*, 4(3), 032002. <https://doi.org/10.1088/2515-7639/abca7b>
- Kumar, V., Azamathulla, H. M., Sharma, K. V., Mehta, D. J. y Maharaj, K. T. (2023). The state of the art in deep learning applications, challenges, and future prospects: A comprehensive review of flood forecasting and management. *Sustainability*, 15(13), 10543. <https://doi.org/10.3390/su151310543>
- Lakshman, K., Kaluri, R., Gundluru, N., Alzamil, Z. S., Rajput, D. S., Khan, A. A., ... y Alhussen, A. (2022). A review on deep learning techniques for IoT data. *Electronics*, 11(10), 1604. <https://doi.org/10.3390/electronics11101604>
- Lee, G. Y., Dam, T., Ferdaus, M. M., Poenar, D. P. y Duong, V. N. (2024). Unlocking the capabilities of explainable few-shot learning in remote sensing. *Artificial Intelligence Review*, 57(7), 169. <https://doi.org/10.1007/s10462-024-10803-5>
- Li, H., Zhu, M., Li, F. y Skitmore, M. (2024). Solving flood problems with deep learning technology: Research status, strategies, and future directions. *Sustainable Development*, 32(6), 7011-7035. <https://doi.org/10.1002/sd.3074>
- Manzoor, Z., Ehsan, M., Khan, M. B., Manzoor, A., Akhter, M. M., Sohail, M. T., ... y Abioui, M. (2022). Floods and flood management and its socio-economic impact on Pakistan: A review of the empirical literature. *Frontiers in Environmental Science*, 10, 1021862. <https://doi.org/10.3389/fenvs.2022.1021862>
- Mishra, B., Dahal, A., Luintel, N., Shahi, T. B., Panthi, S., Pariyar, S. y Ghimire, B. R. (2022). Methods in the spatial deep learning: Current status and future direction. *Spatial Information Research*, 30(2), 215-232. <https://doi.org/10.1007/s41324-021-00425-2>
- Mishra, B. K., Kumar, P., Saraswat, C., Chakraborty, S. y Gautam, A. (2021). Water security in a changing environment: Concept, challenges and solutions. *Water*, 13(4), 490. <https://doi.org/10.3390/w13040490>
- Mittal, S. y Vaishay, S. (2019). A survey of techniques for optimizing deep learning on GPUs. *Journal of Systems Architecture*, 99, 101635. <https://doi.org/10.1016/j.sysarc.2019.101635>
- Muhammad, D. y Bendeche, M. (2024). Unveiling the black box: A systematic review of explainable artificial intelligence in medical image analysis. *Computational and Structural Biotechnology Journal*. <https://doi.org/10.1016/j.csbj.2024.08.005>
- Nascimento, R. G., Fricke, K. y Viana, F. A. (2020). A tutorial on solving ordinary differential equations using Python and hybrid physics-informed neural network. *Engineering Applications of Artificial Intelligence*, 96, 103996. <https://doi.org/10.1016/j.engappai.2020.103996>
- Perera, D., Seidou, O., Agnihotri, J., Rasmy, M., Smakhtin, V., Coulibaly, P. y Mehmood, H. (2019). Flood early warning systems: A review of benefits, challenges, and prospects. UNU-INWEH.

- Rai, H. M., Yoo, J. y Razaque, A. (2024). Comparative analysis of machine learning and deep learning models for improved cancer detection: A comprehensive review of recent advancements in diagnostic techniques. *Expert Systems with Applications*, 255, 124838. <https://doi.org/10.1016/j.eswa.2024.124838>
- Rahman, M. S., Ghosh, T., Aurna, N. F., Kaiser, M. S., Anannya, M. y Hosen, A. S. (2023). Machine learning and Internet of Things in Industry 4.0: A review. *Measurement: Sensors*, 28, 100822. <https://doi.org/10.1016/j.measen.2023.100822>
- Rao, A. S., Radanovic, M., Liu, Y., Hu, S., Fang, Y., Khoshelham, K., ... y Ngo, T. (2022). Real-time monitoring of construction sites: Sensors, methods, and applications. *Automation in Construction*, 136, 104099. <https://doi.org/10.1016/j.autcon.2021.104099>
- Reed, D., Gannon, D. y Dongarra, J. (2022). Reinventing high performance computing: Challenges and opportunities. *arXiv*, 2203.02544. <https://doi.org/10.48550/arXiv.2203.02544>
- Sen, Z. (2021). Reservoirs for water supply under climate change impact: A review. *Water Resources Management*, 35(11), 3827-3843. <https://doi.org/10.1007/s11269-021-02925-0>
- Shen, C., Appling, A. P., Gentine, P., Bandai, T., Gupta, H., Tartakovsky, A., ... y Lawson, K. (2023). Differentiable modelling to unify machine learning and physical models for geosciences. *Nature Reviews Earth & Environment*, 4(8), 552-567. <https://doi.org/10.1038/s43017-023-00450-9>
- Schumann, G., Giustarini, L., Tarpanelli, A., Jarihani, B. y Martinis, S. (2023). Flood modeling and prediction using earth observation data. *Surveys in Geophysics*, 44(5), 1553-1578. <https://doi.org/10.1007/s10712-022-09751-y>
- Shuvo, M. M. H., Islam, S. K., Cheng, J. y Morshed, B. I. (2022). Efficient acceleration of deep learning inference on resource-constrained edge devices: A review. *Proceedings of the IEEE*, 111(1), 42-91. <https://doi.org/10.1109/jproc.2022.3226481>
- Singh, S., Mishra, K., Chavan, R. y Tiwari, H. L. (2023, December). Advancements and challenges in hydrological modeling: A comprehensive review. In *International Conference on Hydraulics, Water Resources and Coastal Engineering* (pp. 423-442). Springer Nature Singapore.
- Soares, L. M. V. y Do Carmo Calijuri, M. (2021). Deterministic modelling of freshwater lakes and reservoirs: Current trends and recent progress. *Environmental Modelling & Software*, 144, 105143. <https://doi.org/10.1016/j.envsoft.2021.105143>
- Sundararajan, K., Garg, L. y Srinivasan, K. (2021). A contemporary review on drought modeling using machine learning approaches. *CMES: Computer Modeling in Engineering & Sciences*, 128(2), 1-4. <https://doi.org/10.32604/cmcs.2021.015528>
- Yang, D. yang, Y. y Xia, J. (2021). Hydrological cycle and water resources in a changing world: A review. *Geography and Sustainability*, 2(2), 115-122. <https://doi.org/10.1016/j.geosus.2021.05.003>
- Wang, J., Li, Y., Gao, R. X. y Zhang, F. (2022). Hybrid physics-based and data-driven models for smart manufacturing: Modelling, simulation, and explainability. *Journal of Manufacturing Systems*, 63, 381-391. <https://doi.org/10.1016/j.jmsy.2022.04.004>

- Xiong, J. y Yang, Y. (2024). Climate change and hydrological extremes. *Current Climate Change Reports*, 11(1), 1. <https://doi.org/10.1007/s40641-024-00198-4>
- Yaseen, Z. M. (2023). A new benchmark on machine learning methodologies for hydrological processes modelling: A comprehensive review for limitations and future research directions. *Knowledge-Based Engineering and Sciences*, 4(3), 65-103. <https://doi.org/10.51526/kbes.2023.4.3.65-103>
- Zulfaqar, S. A., Ramli, M. W. A., Tajuddin, W. A. N. W. A., Arman, N. Z., Hassan, C. H. C., Ramzan, M. A., ... y Alias, N. E. (2024). Evaluating flood early warning system and public preparedness and knowledge in urban and semi-urban areas of Johor, Malaysia: Challenges and opportunities. *International Journal of Disaster Risk Reduction*, 104870. <https://doi.org/10.1016/j.ijdrr.2024.104870>