Impluvium

Publicación digital de la Red del Agua UNAM
Número 32, Julio - Septiembre 2025

AGUA E INTELIGENCIA ARTIFICIAL

INTRODUCCIÓN

El agua es, sin duda, el recurso más vulnerable de la Tierra y se encuentra hoy en el centro de los grandes desafíos del siglo XXI. El cambio climático, la urbanización acelerada y la creciente presión agrícola y energética nos obligan a repensar la manera en que gestionamos y protegemos este vital recurso. Frente a este panorama, la inteligencia artificial (IA) ya no aparece como una fantasía futurista, sino como una herramienta estratégica con aplicaciones concretas: una aliada capaz de anticipar sequías, optimizar sistemas de riego, mejorar la calidad del agua y, al mismo tiempo, abrir nuevas preguntas sobre cómo garantizar un uso ético y responsable de la tecnología.

Este número especial de ***Impluvium*** reúne contribuciones que exploran la amplitud y la profundidad de esa relación entre el agua y la inteligencia artificial. El recorrido inicia con un marco conceptual y crítico, donde se reflexiona sobre la ingobernabilidad tecnológica y la urgencia de contar con principios éticos que orienten el desarrollo y la aplicación de la IA. Asimismo, se subraya la importancia de integrar la dimensión social en la gestión de los recursos hídricos, de manera que el avance algorítmico se traduzca en equidad y beneficio comunitario.

A partir de esta base, los artículos muestran aplicaciones concretas que ilustran cómo la IA puede intervenir en todos los eslabones del ciclo hidrológico. Se incluyen estudios sobre la predicción de fenómenos climáticos extremos y sequías, la gestión del agua de riego, la detección temprana de fugas en redes urbanas y la estimación de nutrientes en cuerpos de agua superficiales. También se presentan innovaciones en el tratamiento y la calidad del agua, desde modelos que optimizan la reutilización hasta el diseño de materiales avanzados para la remoción de contaminantes complejos. En conjunto, estos aportes demuestran la capacidad de la IA para procesar enormes volúmenes de datos, mejorar la precisión de los pronósticos y contribuir a la sostenibilidad de los sistemas hídricos.

El número cierra con una reflexión sobre la huella hídrica de la propia inteligencia artificial, recordándonos que el desarrollo digital también implica un consumo significativo de agua y energía. Considerar este aspecto es esencial para que el despliegue tecnológico no agrave las presiones ambientales que busca resolver.

La conclusión es clara: la inteligencia artificial ya no es una promesa distante, sino una herramienta disponible hoy para anticipar sequías, optimizar redes, mejorar la calidad del agua y fortalecer la gobernanza. Los retos que enfrentamos son inmediatos y requieren respuestas ágiles. Adoptar e integrar con rapidez estas innovaciones no solo incrementará la eficiencia, sino que abrirá la puerta a una gestión hídrica más justa, resiliente y sostenible. El futuro del agua depende de las decisiones que tomemos ahora. Por ello, debemos mirar a la inteligencia artificial no solo como un instrumento técnico, sino como un verdadero catalizador de cambio hacia modelos de gestión integrados, inclusivos y responsables. Espero que las ideas y experiencias reunidas en este número de Impluvium inspiren a investigadores, gestores y profesionales a transformar la innovación en acción y a construir, juntos, soluciones que garanticen la seguridad hídrica en un mundo en transformación.

JOSÉ ANTONIO ROMERO GIL
Asesor de investigación en el Instituto de Ingeniería UNAM

Impluvium es una publicación de la Red del Agua UNAM; puede ser reproducida con fines no lucrativos, siempre y cuando no se mutile, se cite la fuente completa y su dirección electrónica. Los artículos compartidos son responsabilidad exclusiva de los autores y no reflejan necesariamente la opinión de la Red del Agua UNAM o de sus miembros.

Comité editorial:
Dr. Fernando J. González Villarreal
Coordinador Técnico Red del Agua UNAM

M. en C. Jorge Alberto Arriaga Medina
Coordinador Ejecutivo de la Red del Agua UNAM

Lic. Johana Cruz López
Coordinadora del Fomento a la Participación del PUMAGUA

Editor invitado:
José Antonio Romero Gil
Asesor de Investigación,
Instituto d eIngeniería UNAM

Coordinación editorial y diseño:
Lic. Joel Santamaría García

Asistente de diseño
Lic. Marie Claire Mendoza Muciño

Publicación digital de la Red del Agua UNAM.
Número 32, Agua e Inteligencia Artificial.
Julio - Septiembre 2025

www.agua.unam.mx/impluvium.html

Impluvium es la publicación digital de divulgación de la Red del Agua UNAM, Año 13, No.32, Julio – Septiembre 2025. Es una publicación trimestral editada por la Universidad Nacional Autónoma de México, Ciudad Universitaria, Delegación Coyoacán, C.P. 04510, Ciudad de México, a través de la Red del Agua de la UNAM, Circuito Escolar, Ciudad Universitaria, Instituto de Ingeniería, edificio 5, Col. Copilco, Del. Coyoacán, C.P. 04510, Ciudad de México, Tel. (55) 56233600 ext.8745, http://www.agua.unam.mx/impluvium.html, jarriagam@iingen.unam.mx. Editor responsable: M. en C. Jorge Alberto Arriaga Medina. Reserva de Derechos al uso Exclusivo: en trámite., ISSN: en trámite, ambos otorgados por el Instituto Nacional del Derecho de Autor. Responsable de la última actualización de este número, Red del Agua UNAM, M. en C. Jorge Alberto Arriaga Medina, Circuito Escolar, Ciudad Universitaria, Instituto de Ingeniería, edificio 5, Col. Copilco, Del. Coyoacán, C.P. 04510, Ciudad de México fecha de la última modificación, Octubre 2025.

CONTENIDO

Introducción 2

José Antonio Romero Gil

ARTÍCULOS

IA y Gestión del Agua en México: Oportunidades y Desafíos 8

Pedro Manuel Núñez García y Mario Óscar Buenfil Rodríguez

Inteligencia artificial en el sector hídrico: comparación, aplicaciones y perspectivas . . 17

Oscar Fernando Hernández López, Héctor Rodríguez Rangel, Leonel Ernesto Amábilis Sosa y José Luis Medina Jiménez

Inteligencia Artificial y Gestión Hídrica: Innovaciones para Comprender y Optimizar el Ciclo del Agua 25

Jonathan Abraham Quintero-García

Inteligencia artificial para la gestión de eventos hidrometeorológicos en regiones altamente vulnerables 33

Laura Conde Báez, Cuauhtémoc F. Pineda Muñoz y José Alfredo Pineda Gómez

Distribución Gumbel y Análisis de Lluvias Extremas: Implementación Computacional Asistida por IA 40
Margarita Preciado, Rodrigo Roblero-Hidalgo y Maritza Arganis

Predicción de variables hidroclimáticas mediante métodos estadísticos e inteligencia artificial 47
Micaela Carmen Quisbert Morillas y José Luis Aragón-Hernández

Predicción de Sequías con Inteligencia Artificial: Herramientas, Tendencias y Desafíos actuales. 56
Brenda Aracely Ramírez-Barraza y Enrique Ávila-Soler

Capacidad autónoma de la Inteligencia Artificial para dilucidar variaciones del comportamiento hidrológico en un paisaje cárstico 63
Israel Medina-Gómez y Didier Omar Gamboa Angulo

Detección Binaria de Fugas en Redes de Distribución de Agua mediante XGBoost: Un Enfoque Basado en IA 69
Elizabeth Pauline Carreño-Alvarado y Gilberto Reynoso-Meza

Intermitencia hídrica, inteligencia artificial y resiliencia democrática 79
Ana Jessica Díaz Figueroa y Juan José Santibañez Santiago

Del AHP al RCCG: Una evolución metodológica para el análisis de la Ingobernabilidad del Ciclo Hidrosocial en Puerto Morelos, Quintana Roo 86
Sebastián Torres Perdigón

La inteligencia artificial y su aplicación en el desarrollo de nuevos materiales para atender retos nacionales en el área de la calidad y saneamiento del agua 96
Adrián Bonilla-Petriciolet, Didilia Ileana Mendoza-Castillo, Hilda Elizabeth Reynel-Ávila y Ma. del Rosario Moreno-Virgen

Tratamientos basados en aprendizaje automático para la reutilización del agua en aplicaciones industriales y urbanas. 104
Jorge Alejandro Silva Rodríguez De San Miguel

Diseño de materiales y tecnologías emergentes para la remoción de contaminantes del agua a través de la IA. 111
Carolina Leyva Enrique Navarro y Laura González, Eduardo Sánchez

Desarrollo de una metodología basada en inteligencia artificial para predecir nitrógeno y fósforo en cuerpos de agua superficiales mediante parámetros in situ y de bajo costo 119
Marco Elenes Alderete, Hector Rodriguez-Rangel, José Luis Medina Jiménez, Leonel Amabilis Sosa y Luis Alberto Morales-Rosales

¿IA para manejo del agua o agua para la IA? Conciencia e información para la toma de decisiones responsables 125
Marissa Mar Pecero y David-Eduardo Guevara-Polo

IA Y GESTIÓN DEL AGUA EN MÉXICO: OPORTUNIDADES Y DESAFÍOS

PEDRO MANUEL NÚÑEZ GARCÍA Y
MARIO ÓSCAR BUENFIL RODRÍGUEZ
Instituto Mexicano de Tecnología del Agua

ARTÍCULO

Resumen

En los últimos cinco años, el desarrollo de la inteligencia artificial (IA) y la oferta de sus aplicaciones se ha acelerado. Este artículo ofrece un panorama de la problemática del agua en México y su contexto global. Se analizan los impactos de la IA mediante sus huellas hídrica, energética y ecológica, ante su uso masivo. Además, se revisa la oferta de aplicaciones de IA en gestión, seguridad y comunicación relacionados al agua, así como áreas de oportunidad en México. Se concluye que los servidores de IA no representan un impacto ambiental preocupante y su uso llevaría a mejores soluciones, pero es esencial que las instituciones encargadas del agua cuenten con recursos, personal y sistemas sólidos para enfrentar los difíciles retos futuros.

Introducción: Necesidad de mejores herramientas de gestión

En México, la distribución del agua es desigual: el sur cuenta con ríos caudalosos y el norte es seco, caracterizado por desiertos. El desarrollo urbano y productivo ha acentuado esta condición. En 50 años, la disponibilidad media de agua per cápita se redujo a menos de la mitad y el 50 % de la población vive en zonas de severo estrés hídrico. Según el censo 2020 del INEGI, solo el 34 % del agua residual

recibe tratamiento, mientras 6 millones de personas carecen de drenaje y 5 millones no tienen acceso a agua potable.

El desarrollo económico ha generado desequilibrios ambientales y sociales: perforación de pozos en zonas de veda, ríos usados como drenajes y vertederos, crecimiento poblacional que invade cauces y tala bosques, reduciendo recarga de acuíferos e incrementando riesgo de inundaciones. Se subsidia energía y agua a la agricultura, aunque más de la mitad se desperdicia o contamina, representando este sector el 76 % del consumo nacional. Esto ha exacerbado conflictos entre usuarios, comunidades y estados, incluso en la frontera con E.E. U.U., como refleja la dificultad reciente para cumplir el Tratado de Aguas de 1944.

Figura 1. Estres hídrico en el mundo para el 2050

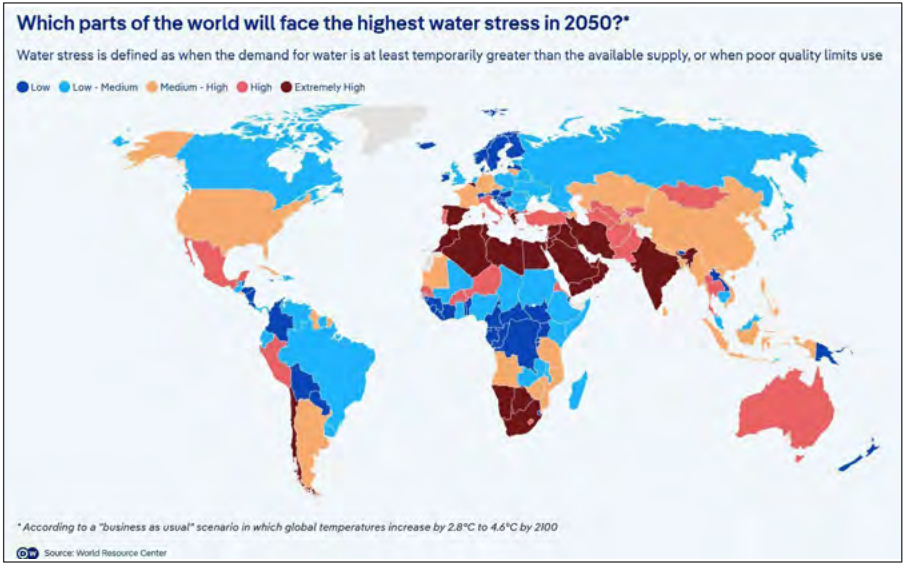

El cambio climático amplifica la presión sobre los recursos. Para 2050 se proyecta que México y Perú tendrán estrés hídrico alto, y Chile extremadamente alto (véase Figura 1). México, por su población mayor, enfrentará una exposición significativa a la falta de agua y riesgos asociados.

Figura 2. Evolución histórica del Earth Overshoot Day

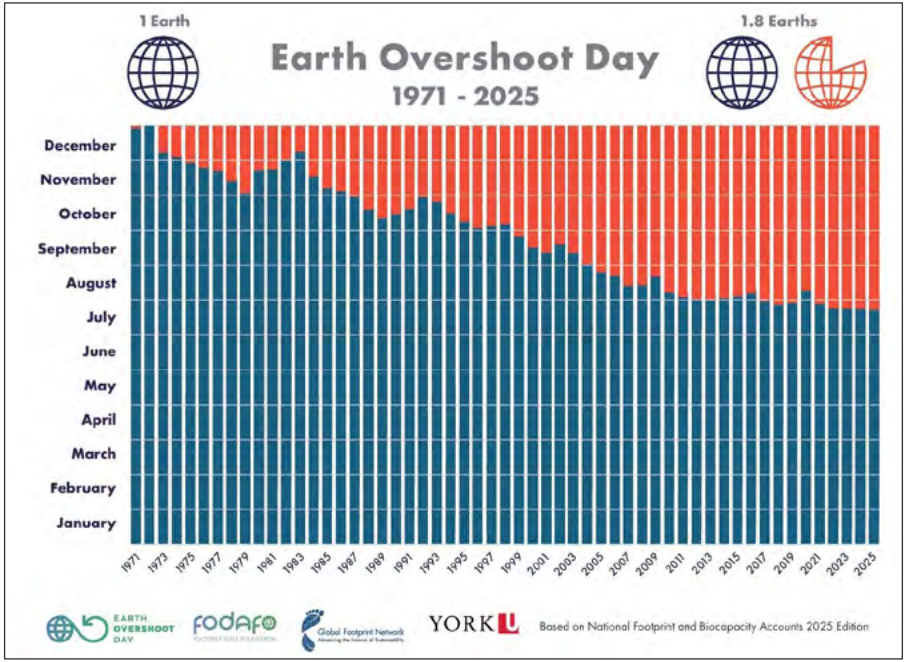

El patrón de sobreexplotación de recursos es global. Para generar conciencia social se ideó el "Global Overshoot Day" que señala que los recursos ambientales que la humanidad podría usar en un año, nos los acabamos antes del año. Ese simbólico día se ha ido adelantado progresivamente, reflejando que hay un déficit ecológico planetario casi la mitad del año (véase Figura 2). La Global Footprint Network calculó que desde la década de los 70, México rebasó su capacidad regenerativa, consumiendo más recursos de los que puede renovar y emitiendo más desechos de los que puede absorber (véase Figura 3).

Por ello, es fundamental implementar la gestión integrada del agua (GIRH) y aprovechar herramientas tecnológicas, incluida la inteligencia artificial (IA), además de fortalecer capacidades de técnicos, especialistas y organismos responsables, así como mejorar la conciencia ciudadana.

Figura 3. Huella Ecologica vs Biocapacidad en México

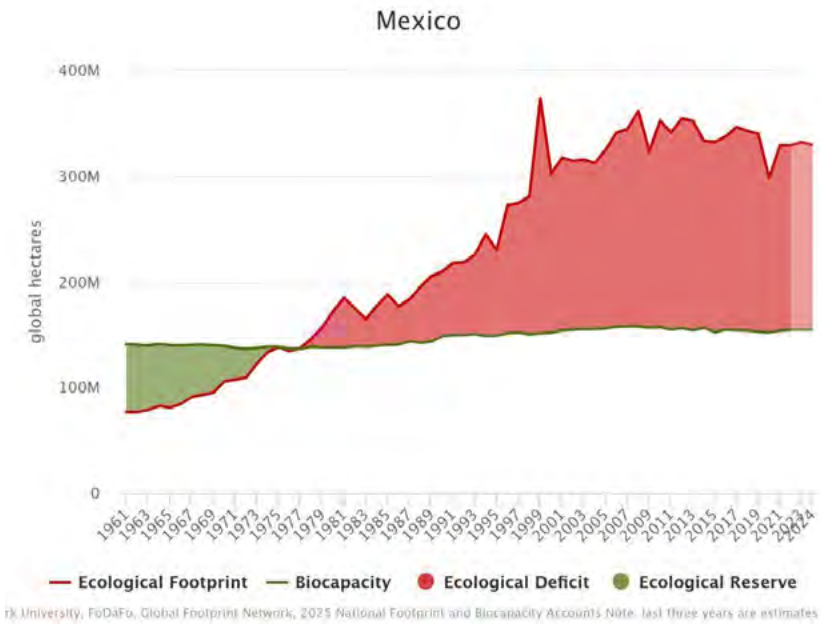

Desarrollo

Inteligencia Artificial (IA) ¿amenaza o aliada?

La inteligencia artificial despierta entusiasmo en la ciencia, la política y la gestión hídrica por su potencial para abordar problemas complejos, democratizar el acceso a la información y generar conciencia sobre la importancia de los recursos hídricos. Sin embargo, este optimismo convive con preocupaciones sobre su impacto real, especialmente en términos de consumo de energía y agua asociado a su entrenamiento, operación y procesamiento de información en centros de datos, que constituyen la infraestructura central de la IA.

Existen diferentes estimaciones sobre el consumo hídrico de la IA. Por ejemplo, para un modelo como GPT-3 se estima que un requerimiento de 0.5 litros por cada 10 a 50 consultas (Li et al., 2025). Por otro lado, según Sam Altman, unas 1000 consultas en el chatbot consumen alrededor de 0.3 de litros

de agua, es decir, 1 millón de consultas consumirían 0.3 m³, menos de lo que consume una familia (vivienda) al día. A nivel global, la demanda hídrica anual en los centros de entrenamiento de IA podría requerir unos 70 hectómetros cúbicos de agua al año (Lei et al, 2025), equivalente al consumo de una ciudad de medio millón de habitantes.

En el siguiente cuadro (véase Tabla 1) se muestra una comparación entre la huella hídrica de ChatGPT y diversos productos de consumo básico, evidenciando que, a pesar de las distintas estimaciones, el consumo de agua y energía al usar IA no es significativo en la mayoría de los escenarios.

De manera similar, frente a métodos tradicionales de análisis de datos y cálculos hidráulicos, el uso de IA puede ser más eficiente en términos energéticos, reduciendo el tiempo de procesamiento requerido en búsquedas extensas en internet, consultas telefónicas o la revisión de voluminosos repositorios de información (véase Figura 4).

Producto / Servicio	Unidad	Huella hídrica aproximada (L)	Fuente
ChatGPT	**50 consultas**	**~0.50 L**	**Li, et al., 2025**
Carne de res	1 kg	~15,400 L	Water Footprint Network
Pollo	1 kg	~4,300 L	Water Footprint Network
Maíz	1 kg	~900 L	Water Footprint Network
Trigo	1 kg	~1,600 L	Water Footprint Network
Café	1 taza (125 ml)	~140 L	Water Footprint Network
Algodón	1 camiseta (250 g de algodón)	~2,700 L	Water Footprint Network

Tabla 1. Huella Hídrica de IA vs diversos productos de consumo básico

El cerebro humano, a pesar de su reducido tamaño, consume aproximadamente el 20 % de la energía corporal total. La elevada demanda energética no se limita al pensamiento, sino que incluye la regulación de emociones, movimientos y percepción del entorno. Estas actividades generan calor, requiriendo un eficiente sistema de enfriamiento a través de la circulación sanguínea y períodos de reposo, como el sueño, esenciales para mantener un funcionamiento óptimo (Kandel et al., 2021). En contraste, la IA puede procesar cientos de miles de consultas diariamente y sin interrupción, y si bien consume energía y genera

Figura 4. Comparación del consumo energético tradicional vs IA

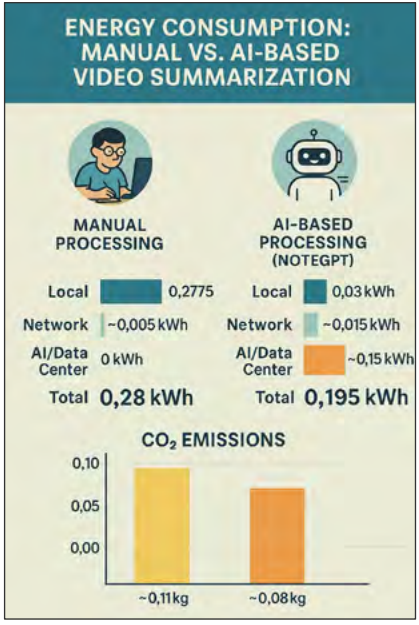

calor en sus circuitos, su requerimiento hídrico para enfriamiento es comparable al de unos pocos hogares, lo que resulta insignificante frente a las necesidades energéticas y de agua del cerebro humano (Hoffmann et al., 2022).

Estos análisis muestran que el consumo de recursos de la IA es relativamente bajo en comparación con su potencial, lo que la convierte en una herramienta eficiente y aparentemente sostenible para la toma de decisiones.

Oferta de aplicaciones de IA en GIRH

La IA está transformando la planificación y protección del agua, con aplicaciones en pronósticos hidrológicos, alerta temprana, manejo de cuencas, operación de centrales hidroeléctricas, detección de fugas, drenaje pluvial, análisis satelital, riego, tratamiento de aguas residuales y monitoreo de contaminantes.

En Corea del Sur, el Korean Water Resource Research cuenta con un departamento especializado en IA que ha implementado esta tecnología en el manejo sostenible de los recursos hídricos, desarrollando diversas plataformas que integran procesos de ML, IoT, Big Data e IA (véase Figura 5).

En gestión de riesgos, Estados Unidos, Alemania y Reino Unido han implementado el modelo Google Flood Hub para pronosticar crecidas fluviales con días de anticipación. En España, Francia y Andorra, el proyecto AI4FLOOD fortalece la prevención ante inundaciones. En Nigeria y Mozambique, este modelo se vincula a alertas tempranas que activan

Figura 5. Aplicaciones de IA en Corea del Sur

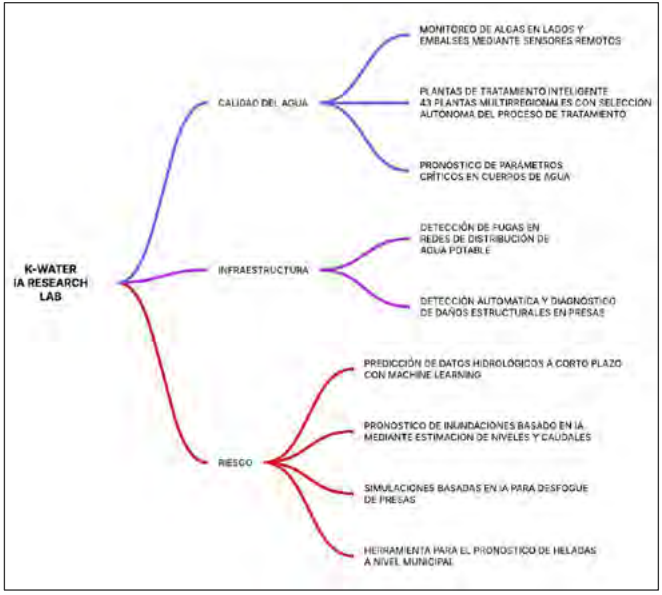

transferencias monetarias a comunidades vulnerables antes del impacto (International Rescue Committee, 2023; Anticipation Hub, 2023). En China, el modelo Lingxi de Beijing anticipa lluvias extremas de seis horas y ya se aplica en el sector asegurador.

La IA también se usa en mantenimiento predictivo de infraestructura hidráulica, mediante plataformas que analizan datos de sensores e historiales para anticipar fallas y priorizar inversiones. Paquetes como IBM Máximo, SAP EAM, Innovyze y servicios en la nube (Microsoft, AWS, Google) integran modelos predictivos y sistemas IoT. En Singapur, EE. UU. y la U. E. son estándar, mientras que en México y Latinoamérica apenas comienzan a implementarse.

En calidad del agua, la IA detecta contaminantes y anticipa deterioro ambiental mediante monitoreo en redes y plantas de tratamiento. Algoritmos optimizan potabilización y desinfección, y en aguas residuales mejoran el control de contaminantes y la gestión de lodos. Estas herramientas benefician tanto a países desarrollados, donde forman parte de sistemas consolidados, como a regiones emergentes, donde apoyan a ampliar saneamiento y seguridad hídrica. En agricultura, sistemas inteligentes recomiendan riego óptimo según suelo, clima y cultivo (véase Tabla 2).

Nº	Tema	Aplicación en zonas urbanas	Beneficio esperado
1	Detección de fugas	Redes de abastecimiento con sensores	Reducción de pérdidas de agua
2	Optimización energética	Plantas de bombeo eficientes	Menor costo operativo y emisiones
3	Potabilización avanzada	Filtración y desinfección mejorada	Agua más segura para consumo
4	Monitoreo en tiempo real	Sensores en redes de distribución	Control continuo de calidad
5	Alcantarillado inteligente	Redes con control automatizado	Prevención de desbordamientos
6	Tratamiento descentralizado	Plantas en zonas periurbanas	Mayor cobertura de saneamiento
7	Reuso en espacios verdes	Agua tratada para riego urbano	Ahorro de agua potable
8	Recarga de acuíferos	Infiltración con aguas tratadas	Fortalecimiento de reservas subterráneas
9	Captación de lluvia	Sistemas en viviendas y edificios	Aprovechamiento local del recurso
10	Plataformas digitales	Gestión integral del ciclo urbano	Mejora en planeación y control
11	Alertas tempranas	Sistemas para sequías e inundaciones	Reducción de riesgos y daños
12	Modelación hidrodinámica	Planeación del drenaje pluvial	Prevención de encharcamientos
13	Desinfección eficiente	Procesos de bajo consumo energético	Menor costo de potabilización
14	Inspección aérea	Uso de drones en infraestructura	Detección rápida de fallas
15	Energías renovables	Bombeo y tratamiento solar/eólico	Reducción de huella energética
16	Economía circular	Reuso de agua en procesos urbanos	Disminución de demanda de agua nueva
17	IA para predicciones	Pronóstico de consumo y fugas	Planificación más precisa
18	Datos abiertos	Plataformas de información ciudadana	Transparencia y participación
19	Control de contaminantes	Tecnologías avanzadas en PTAR	Agua más limpia y segura
20	Gestión de lodos	Aprovechamiento energético y compost	Reducción de residuos y costos
21	Sectorización y telemetría	Redes con medición por zonas	Mejor control de presión y fugas
22	IA para demanda	Predicción diaria y estacional	Ajuste dinámico del suministro
23	Alcantarillado separado	Pluvial y residual independientes	Menor riesgo de contaminación
24	Plantas modulares	Tratamiento en colonias y fraccionamientos	Saneamiento flexible y escalable
25	Reuso industrial	Agua tratada en procesos de bajo riesgo	Ahorro de agua potable en industrias
26	Captación en grandes superficies	Centros comerciales, estadios, mercados	Reducción de demanda en la red
27	Reutilización de biosólidos	Abono y energía en zonas urbanas	Valor agregado a residuos
28	Sensores en colectores	Medición de caudal y calidad	Control de descargas y contaminación
29	Gestión ciudadana digital	Apps para reportes de fugas y fallas	Respuesta más rápida a problemas
30	Tarifas y pagos digitales	Sistemas diferenciados y electrónicos	Incentivo al ahorro y reuso

Tabla 2. Catalogo de aplicaciones de IA en manejo administración del agua en zonas urbanas

Conclusiones

La IA no constituye una amenaza para la seguridad hídrica, sino una herramienta cuyo impacto dependerá de su diseño, usos y regulación. Los hallazgos de este estudio señalan que su huella hídrica y energética no representa un riesgo adicional frente a los procesos tradicionales de análisis o al desempeño humano, y si se aprovecha adecuadamente, ofrece oportunidades para mejorar la planeación, monitoreo y gestión de los recursos hídricos.

Fortalecer instituciones públicas y de investigación, como el IMTA, es indispensable para garantizar soluciones técnicas y socialmente justas. Instituciones sólidas, profesionales y financieramente autosuficientes generan confianza y permiten vigilar, certificar y mejorar los servicios relacionados con agua, salud y seguridad ambiental. México, rezagado en investigación e innovación tecnológica, debe avanzar a un liderazgo si pretende responder a los retos del estrés hídrico.

Se requieren además marcos regulatorios claros que eviten la “tragedia de los comunes” en el uso de acuíferos, ríos y bosques, así como en la

utilización ética de la IA. La coerción recíproca, acordada y vigilada (Hardin, 1968), es clave para asegurar el aprovechamiento sostenible.

Finalmente, la concienciación social es tan crucial como la tecnología. La IA puede apoyar campañas educativas que promuevan el uso responsable del agua y la reducción de la huella ecológica. Pero esto también implica cuestionar el modelo de crecimiento ilimitado que presiona a los ecosistemas. Reducir nuestra huella puede incluir moderación demográfica y de consumo, complementando los esfuerzos tecnológicos y normativos, recordando que el desafío es tan cultural y ético como científico.

Bibliografía

Hardin, G. (1968). *The Tragedy of the Commons. Science,* 162(3859), 1243–1248. https://doi.org/10.1126/science.162.3859.1243

Kandel, E. R., Koester, J. D., Mack, S. H., & Siegelbaum, S. A. (2021). *Principles of Neural Science* (6ª ed.). McGraw Hill Professional, Nueva York, EE. UU.

Lei, N., Lu, J., Cheng, Z., Cao, Z., Arman Shehabi, & Masanet, E. (2023). *Geospatial assessment of water footprints for hyperscale data centers in the United States. Journal of Physics Conference Series,* 2600(17), 172003. IOP Publishing, Bristol, Reino Unido.

Li, P., Yang, J., Islam, M., & Ren, S. (2025). *Making AI Less "Thirsty": Uncovering and Addressing the Secret Water Footprint of AI Models.*

York University, FoDaFo, Global Footprint Network (2025). *National Footprint and Biocapacity Accounts, preliminary 2025 Edition.* Global Footprint Network, Oakland, CA, USA.

INTELIGENCIA ARTIFICIAL EN EL SECTOR HÍDRICO: COMPARACIÓN, APLICACIONES Y PERSPECTIVAS

OSCAR FERNANDO HERNÁNDEZ LÓPEZ,
HÉCTOR RODRÍGUEZ RANGEL,
LEONEL ERNESTO AMÁBILIS SOSA Y
JOSÉ LUIS MEDINA JIMÉNEZ
Tecnológico Nacional De México, Instituto Tecnológico De Culiacán

ARTÍCULO

Resumen

La inteligencia artificial ha demostrado ser una herramienta valiosa para la gestión del agua, debido a que responde de forma dinámica al crecimiento poblacional y al cambio climático. Su capacidad para detectar patrones complejos no lineales permite diversas aplicaciones. Técnicas como redes neuronales, máquinas de vectores de soporte y algoritmos preentrenados han resultado especialmente útiles. Asimismo, la combinación de IA con tecnologías como el Internet de las Cosas (IoT), la computación en la nube y enfoques estadísticos tradicionales puede mejorar la eficiencia en la gestión hídrica. Sin embargo, aún persisten desafíos importantes, como la necesidad de tener datos suficientes y confiables, así como la limitada interpretabilidad de algunos modelos. Así, es importante contar con grupos de trabajo interdisciplinarios que permitan hacer un uso responsable y certero de la información del recurso hídrico generada con IA.

Introducción

La gestión del agua es vital para la sociedad, con desafíos que varían según el contexto de cada comunidad. Garantizar el acceso en zonas urbanas y rurales es crucial, especialmente ante el crecimiento poblacional y el cambio climático.

La inteligencia artificial (IA) se ha convertido en una herramienta poderosa por su capacidad para procesar grandes volúmenes de datos, identificar patrones complejos y generar predicciones precisas (Hajirad, 2025, p.1). La variedad de variables que la IA puede considerar supera a los métodos estadísticos tradicionales. Por ejemplo, se comparó, mediante el coeficiente de determinación (R^2), la capacidad de un modelo estadístico tradicional (regresión lineal) y uno basado en IA (Random Forest), ambos aplicados a pronósticos de calidad del agua. El modelo tradicional presentó valores de R^2 según el parámetro: conductividad (0.471–0.858), pH (0.700–0.929), nitratos totales (0.893–0.973) y alcalinidad total (0.358–0.835). En cambio, el modelo de IA mostró un desempeño superior, con valores de R^2 mayores a 0.99: DQO (0.99954), $N\text{-}NH_4^+$ (0.99989), fósforo total (0.99988) y nitrógeno total (0.99989). Aunque los parámetros difieren, ambos estudios comparten la misma aplicación, evidenciando la ventaja de la IA en términos de precisión (Fernandez et al, 2023, p. 16; Sun et al, 2024, p. 10).

Los métodos estadísticos funcionan bien con pocos datos y contextos simples, pero pierden eficacia ante mayor complejidad. En esos casos, la IA ofrece soluciones más rápidas y precisas. Esta capacidad permite tomar decisiones informadas para la gestión del agua, el manejo de crisis y la mitigación de riesgos por escasez o inundaciones (Kamyab et al, 2023, p. 5).

Operativamente, la IA integrada en sistemas inteligentes reduce costos al automatizar la recolección y el análisis de datos. Mejora la eficiencia en sistemas como el riego inteligente, que ajusta el uso de agua según la humedad del suelo, y favorece la sostenibilidad al evitar desperdicios.

La IA evoluciona junto con el sector hídrico, abriendo nuevas formas de abordar los problemas del agua y buscar soluciones más exigentes. Ha revolucionado el análisis de datos hídricos, mejorando la predicción de caudales, el análisis de calidad del agua y la gestión de cuencas (Biazar et al, 2025, p. 2).

Gestión de Recursos Hídricos mediante IA

La inteligencia artificial (IA) tiene múltiples aplicaciones en cuanto a la gestión del sector hídrico. Tanto en el monitoreo de calidad del agua como en la infraestructura hidráulica (ver figura 1). Se destaca en la toma de decisiones, optimizar el consumo, monitorear la calidad, detectar fugas, identificar contaminantes, automatizar el riego y anticipar lluvias o sequías. Algunos de los modelos y algoritmos más usados en el sector hídrico son ANN, MLP, LSTM, RF y VMS. Por ejemplo, un estudio reciente detectó metales pesados en agua y aguas residuales usando múltiples algoritmos de aprendizaje automático, demostrando su utilidad como sistema de alerta temprana ante contaminantes que requieren análisis especializados (Biazar et al, 2025, p. 13).

Figura 1.

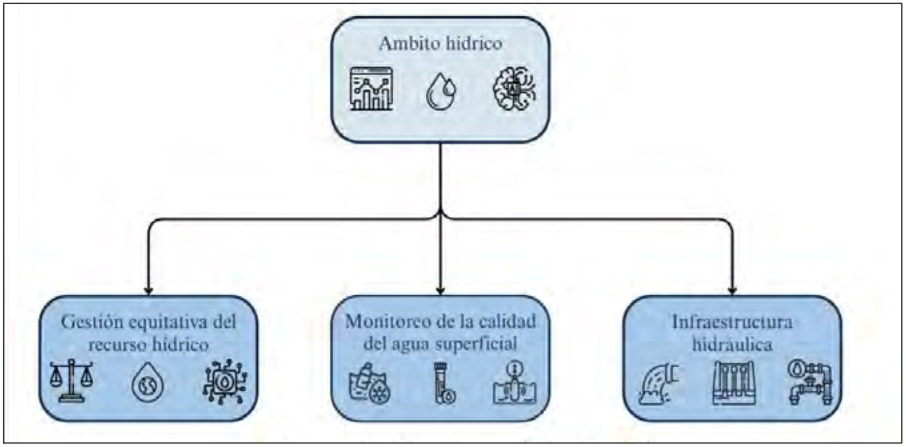

Gestión equitativa del recurso hídrico

En México, la cantidad de tomas de agua en operación varía según factores como población, urbanización y economía. Por ello, modelos de IA buscan distribuir equitativamente el recurso entre sectores clave (ver figura 2), promoviendo una gestión sostenible con criterios hidrológicos, sociales y ambientales.

Figura 2.

En este contexto, la IA cobra relevancia al detectar patrones complejos no lineales mediante técnicas como redes neuronales (ANN) y máquinas de vectores de soporte (SVM) (ver figura 2).

Las ANN son altamente adaptables y pueden modelar patrones complejos, siempre que cuenten con suficientes datos de entrenamiento. Por otro lado, las SVM se desempeñan mejor en contextos con conjuntos de datos limitados y en problemas donde las condiciones y variables están bien definidas (Hirko et al, 2025, p. 14).

También se emplean técnicas avanzadas de aprendizaje automático como Random Forest, GBM y redes LSTM, que han mostrado buenos resultados en la planificación hídrica.

Monitoreo de la calidad del agua superficial

Una de las claves para aprovechar el potencial de la IA en la gestión del agua es la incorpora-

ción del Internet de las Cosas (IoT), que permite generar datos precisos en tiempo real. Esta combinación permite monitoreo continuo y predicciones precisas de calidad del agua, mejorando la gestión y reduciendo la contaminación en la industria, agricultura y abastecimiento urbano (Biazar et al, 2025, p. 12).

La IA detecta patrones en datos de sensores mucho más rápido que los métodos tradicionales, que dependen de reactivos, personal especializado y técnicas como espectrofotometría o cromatografía. El impacto de la IA en este ámbito es notable. Aunque los resultados dependen del contexto, modelo y calidad de los datos, se ha demostrado que la IA puede reducir errores en un 30 %, mejorar el monitoreo en un 40 % y optimizar la detección en tiempo real (Zou et al, 2025, p. 2).

Sin embargo, no se pueden dejar de lado los métodos ya utilizados en el sector hídrico, por lo que la integración de la inteligencia artificial suele ser parcial y no total. La combinación de métodos tradicionales con modelos de IA —modelos híbridos— ha resultado efectiva para captar variaciones a corto plazo y tendencias a largo plazo en la calidad del agua (Biazar et al, 2025, p. 12).

Infraestructura hidráulica

La inteligencia artificial optimiza la infraestructura hidráulica al facilitar el monitoreo, la detección de fugas y mejoras operativas. Modelos como YOLOv3, una red neuronal para detección de objetos, pueden entrenarse con imágenes de alta resolución para identificar niveles de agua en presas. En un estudio reciente, este modelo alcanzó una precisión promedio del 90.27 % en la detección de presas de retención y 91.89 % en aquellas que contenían agua (Xia et al, 2025, p. 1).

Las imágenes captadas por drones o satélites permiten el monitoreo en tiempo real para detectar riesgos. Los drones ofrecen mayor resolución; los satélites, mayor cobertura. En ambos casos, los modelos pueden optimizarse con imágenes grandes, coordenadas refinadas y arquitecturas en cascada multimodelo, lo que mejora el monitoreo en terrenos complejos y condiciones hídricas variables (Xia et al, 2025, p. 2).

Figura 3.

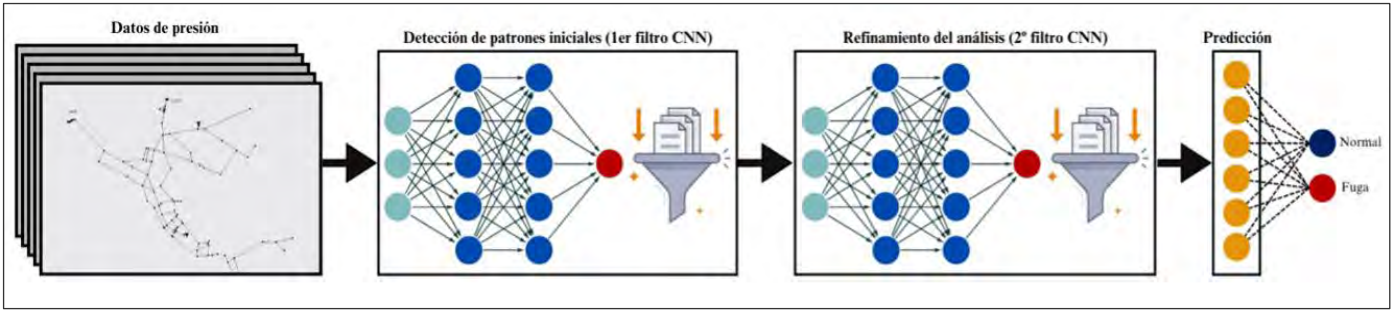

Modelos similares a YOLOv3 se han vuelto clave para detectar fugas. Un enfoque eficaz combina una red cGAN, que genera imágenes simuladas con datos como caudal y nivel del agua, junto con una red 3D-CNN que las analiza para identificar fugas. Este proceso (ver figura 3) muestra el flujo de datos desde sensores hasta la predicción final del sistema.

Un aspecto clave, y a la vez un gran desafío, es que los modelos de IA dependen del contexto. Por ello, deben entrenarse para cada red hidráulica, ya que la infraestructura varía en dimensiones y complejidad. Factores como diámetro, longitud y disposición de tuberías influyen significativamente en la detección precisa de fugas (Jun & Jung, 2025, p. 14).

Conclusión

La inteligencia artificial se ha consolidado como una herramienta valiosa en el sector hídrico, al permitir evaluaciones más precisas y eficientes ante tareas complejas que superan la capacidad humana y herramientas tradicionales. Sin embargo, no reemplaza el criterio experto, sino que lo complementa. Su aplicación implica desafíos como la “caja negra”, donde las decisiones no siempre son interpretables,

especialmente en emergencias. Por ello, requiere datos confiables y personal capacitado. Tecnologías como la computación paralela y la nube fortalecen su uso al permitir análisis simultáneos y acceso remoto, ampliando la velocidad, flexibilidad y alcance de soluciones para una gestión hídrica sostenible. Más que nunca, requieren equipos de trabajo con expertos relacionados con el sector hídrico y con los relacionados con las ciencias de datos y, por supuesto, inteligencia artificial.

Bibliografía

Hajirad, I. (2025). Role of Artificial Intelligence in Improving Water Resource Management: From Demand Forecasting to Waste Reduction and Water Crisis Mitigation. Journal of Nutrition and Food Processing, Lewes, USA.

Biazar, S. M., Golmohammadi, G., Nedhunuri, R. R., Shaghaghi, S., & Mohammadi, K. (2025). Artificial Intelligence in Hydrology: Advancements in Soil, Water Resource Management, and Sustainable Development. Sustainability, Basel, Suiza.

Zou, S., Ju, H., & Zhang, J. (2025). Water Quality Management in the Age of AI: Applications, Challenges, and Prospects. Water, Basel, Suiza.

Xia, Z., Yu, S., Zhang, N., Wang, J., Cao, Y., Yue, F., & Zhang, H. (2025). A New Monitoring Method for the Water-Filled Status of Check Dams Using Remote Sensing and Deep Learning Techniques. Water, Basel, Suiza.

Hirko, D.B., Du Plessis, J.A. & Bosman, A. (2025). Review of machine learning and WEAP models for water allocation under climate change. Earth Science Informatics, Cham, Suiza.

Kamyab, H., Khademi, T., Chelliapan, S., SaberiKamarposhti, M., Rezania, S., Yusuf, M., Farajnezhad, M., Abbas, M., Jeon, B. H., & Ahn, Y. (2023). The latest innovative avenues for the utilization of artificial intelligence and big data analytics in water resource management. Results in Engineering, Ámsterdam, Países Bajos.

Jun, S., & Jung, D. (2025). Exploration of deep learning leak detection model across multiple smart water distribution systems: Detectable leak sizes with AMI meters. Water Research X, Ámsterdam, Países Bajos.

Fernandes, A. C. P., Fonseca, A. R., Pacheco, F. A. L., & Sanches Fernandes, L. F. (2023). Water quality predictions through linear regression – A brute force algorithm approach. MethodsX, Ámsterdam, Países Bajos.

Sun, J., Guan, X., Sun, X., Cao, X., Tan, Y., & Liao, J. (2024). Water quality prediction and carbon reduction mechanisms in wastewater treatment in Northwest cities using Random Forest Regression model. Scientific Reports, Cham, Suiza.

INTELIGENCIA ARTIFICIAL Y GESTIÓN HÍDRICA: INNOVACIONES PARA COMPRENDER Y OPTIMIZAR EL CICLO DEL AGUA

JONATHAN ABRAHAM QUINTERO-GARCÍA
El Colegio de San Luis, A.C.

ARTÍCULO

Resumen

La inteligencia artificial (IA) emerge como herramienta clave para enfrentar los retos del agua ante el cambio climático, la urbanización acelerada y la creciente demanda. Este artículo examina sus aplicaciones en el ciclo hidrológico: predicción de lluvias e infiltraciones, monitoreo en tiempo real de acuíferos y redes de distribución, optimización del riego agrícola, reducción del consumo industrial y detección de contaminantes. Asimismo, se destacan sus usos en plataformas de gobernanza hídrica y sistemas de alerta temprana, junto con los desafíos éticos y técnicos que plantea para garantizar un acceso equitativo. Integrada en una gestión participativa, la IA puede impulsar sostenibilidad y justicia en el manejo del agua.

Introducción

El agua es fundamental para la vida, el progreso social y la economía. Sin embargo, el cambio climático, la sobreexplotación y la rápida urbanización amenazan su disponibilidad y calidad (WWAP, 2022). Comprender y manejar el ciclo del agua se ha convertido en un desafío complicado, ya que hay muchas variables y niveles involucrados. Aquí es donde la IA puede ayudar, ya que tiene la capacidad de procesar grandes cantidades de datos y hacer

predicciones, lo cual es crucial para una mejor gestión de los recursos hídricos. Este artículo examina cómo la IA puede desempeñar un papel en las diferentes etapas del ciclo hidrológico y su potencial para una planificación sostenible del agua.

Desarrollo

1. El ciclo hidrológico como sistema complejo

El ciclo del agua incluye procesos como la evaporación, la condensación, la precipitación, la escorrentía, la infiltración y el almacenamiento (Chow et al., 1988) (Véase Figura 1). Estos procesos no funcionan de manera independiente; en realidad, forman un sistema dinámico donde intervienen factores climáticos, geográficos y humanos. La IA ayuda a analizar este sistema al integrar datos variados (como datos meteorológicos, hidrológicos y de uso del suelo) para descubrir patrones ocultos y crear modelos predictivos. Por ejemplo, se han utilizado algoritmos de aprendizaje profundo para simular cambios en la precipitación bajo diferentes escenarios y la planificación del agua a varias escalas.

de cambio climático, evaluando cómo esto afecta la recarga de acuíferos y las inundaciones. Gracias a estas herramientas, se mejora la gestión preventiva

Figura 1. Ciclo hidrológico e Inteligencia Artificial
Elaborado con Generador de Imágenes, Microsoft Bing (2025).

2. Monitoreo en tiempo real mediante sensores e IA

también activa mecanismos de alerta temprana y diagnósticos

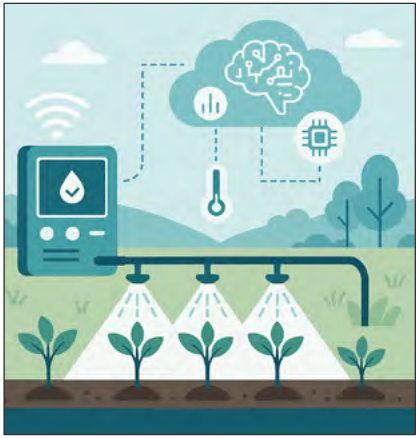

predictivos que pueden prevenir crisis hídricas locales.

Los sensores IoT que se colocan en ríos, represas y áreas urbanas permiten medir el caudal, los niveles y la calidad del agua (Véase Figura 2). Estos dispositivos generan una importante cantidad de datos que, al procesarse con algoritmos de aprendizaje automático, ayudan a detectar fugas, irregularidades y casos de contaminación en tiempo real (Ali, et al., 2025; Taloma, et al., 2025). Incorporar IA en estos sistemas no solo hace más eficiente su operación, sino que

Figura 2. Sistema de riego inteligente con IA en agricultura de precisión
Elaborado con Generador de Imágenes, Microsoft Bing (2025).

3. Modelación predictiva del ciclo hidrológico

Las redes neuronales y los modelos de regresión no lineal son herramientas que permiten anticipar escorrentías, recargas de acuíferos y sequías (Véase Figura 3). Estas herramientas complementan la modelación física tradicional, que es útil para la planificación de cuencas, especialmente cuando se cuentan con datos incompletos (Shen, 2018). Además, el uso de IA ayuda a evaluar diferentes escenarios de gestión, como la construcción de represas o la implementación de políticas de conservación, brindando información clave para la toma de decisiones estratégicas.

4. Optimización del uso del agua en sectores productivos

En la agricultura, la IA permite un riego inteligente al combinar sensores de humedad, pronósticos climáticos e imágenes satelitales, con el objetivo de reducir el desperdicio de agua (Alvim et al., 2022). Este

Figura 3. Sensores urbanos IoT aplicados en redes de agua potable

Elaborado con Generador de Imágenes, Microsoft Bing (2025).

Figura 4. Análisis de calidad del agua con IA

Elaborado con Generador de Imágenes, Microsoft Bing (2025).

enfoque, que se conoce como agricultura de precisión, ha demostrado aumentar considerablemente la eficiencia hídrica y la productividad agrícola. En el sector industrial, la IA se usa para optimizar procesos de reutilización, monitorear ciclos de producción y calcular huellas hídricas, favoreciendo un consumo más racional de este recurso.

5. Calidad del agua y detección de contaminantes

Los algoritmos de aprendizaje supervisado son capaces de analizar datos químicos y microbiológicos para detectar contaminantes emergentes, como metales pesados, pesticidas o microplásticos, ayudando así a reducir riesgos para la salud pública (Chen et al., 2024). Estos sistemas se benefician del uso de espectroscopía y sensores de alta resolución que generan grandes volúmenes de datos que no se pueden analizar manualmente.

6. IA y gobernanza del agua

Las plataformas digitales integran módulos de IA que apoyan la toma de decisiones en la gestión integral de recursos hídri-

cos. Estas herramientas permiten evaluar la asignación de caudales, simular distintos escenarios de demanda y priorizar inversiones en infraestructura (Takeda, et al., 2021). No obstante, hay desafíos éticos que debemos enfrentar: la transparencia de los algoritmos, la dependencia tecnológica, el acaparamiento del agua por pequeños sectores y la inclusión de comunidades vulnerables. Por eso, es crucial diseñar marcos normativos y políticas públicas que aseguren que estas innovaciones promuevan la equidad y la sostenibilidad.

7. México y la inteligencia artificial en la gestión nacional del agua

México enfrenta una crisis hídrica marcada por la sobreexplotación de más del 40% de sus acuíferos, la urbanización acelerada, la industrialización de alta demanda hídrica, la desigualdad en el acceso al agua, la concentración de derechos de agua en pocas manos y los impactos del cambio climático (Barreda, 2025). Ante este panorama, la IA se perfila como herramienta estratégica. Instituciones como CONAGUA y el IMTA exploran modelos predictivos y sistemas de monitoreo para anticipar sequías, gestionar cuencas y optimizar el riego agrícola, como en el Bajío. También se aplican redes neuronales para pronosticar escorrentías y niveles de presas estratégicas, como el Sistema Cutzamala que abastece a gran parte del Valle de México.

Figura 5. Gobernanza digital y toma de decisiones con IA en gestión hídrica

Elaborado con Generador de Imágenes, Microsoft Bing (2025).

El reto principal es que estas innovaciones tecnológicas se traduzcan en una gestión hídrica más equitativa y sostenible, evitando su concentración en pocos sectores y garantizando acceso justo a la información.

Conclusiones

La IA puede transformar la gestión del agua al mejorar el monitoreo, anticipar cambios climáticos y optimizar la distribución en sectores urbanos, agrícolas e industriales. No obstante, sus beneficios dependen de condiciones básicas: calidad de datos, gobernanza efectiva, justicia hídrica y marcos regulatorios sólidos. Sin estos elementos, la tecnología corre el riesgo de reproducir desigualdades, generar dependencia y ampliar brechas de acceso. En lo técnico, esta herramienta debe integrarse en enfoques híbridos que combinen modelos hidrológicos y aprendizaje automático, considerando incertidumbre, validación en distintos climas y explicaciones transparentes. Esto evita sesgos y decisiones automatizadas sin control. Asimismo, se requiere una gestión integral del ciclo de vida de datos y modelos con protocolos de actualización, auditoría y rendición de cuentas.

En gobernanza, se necesitan principios de datos abiertos, estándares interoperables, protección de privacidad y seguridad digital. La participación comunitaria y la ciencia ciudadana enriquecen los modelos y legitiman decisiones. Finalmente, deben impulsarse políticas de financiamiento, capacitación y accesibilidad tecnológica, al tiempo que se atiende la huella ambiental de la infraestructura digital mediante prácticas de “IA verde”.

Aquí hay algunas líneas de acción recomendadas:

1. Establecer un marco regulatorio que incluya evaluaciones de impacto algorítmico, requisitos de transparencia y mecanismos de apelación para los usuarios afectados.
2. Crear una carta de gobernanza de datos hídricos, con atención a la calidad, trazabilidad, metadatos y apertura por defecto, alineada a los principios FAIR.
3. Definir estándares e interoperabilidad para sensores, formatos e interfaces de programación de aplicaciones (APIs), evitando así problemas de “cajas negras” y dependencia de proveedores.
4. Implementar arquitecturas híbridas que combinen modelos físicos y de IA, reportando

la incertidumbre en pronósticos y decisiones operativas.

5. Ofrecer capacitación y fortalecer las instituciones en municipios y operadores, creando laboratorios de políticas y pruebas escalables.
6. Promover la participación: establecer consejos de cuenca y comités ciudadanos con acceso a tableros públicos y datos en tiempo real.
7. Aplicar criterios de equidad territorial a la hora de priorizar inversiones y desplegar sensores e infraestructura digital.
8. Asegurar la sostenibilidad de la IA: exigir en las compras públicas eficiencia energética, reportes sobre huella y planes para el final de vida.

La IA no solo incrementa la eficiencia, sino que también fortalece la resiliencia ante sequías e inundaciones y favorece la justicia hídrica, al hacer más transparentes e inclusivos los procesos de decisión, dentro de una gestión participativa, regulada y con acceso equitativo.

Bibliografía

Ali, A., Hussain, T. y Zahid, A. (2025). Smart Irrigation Technologies and Prospects for Enhancing Water Use Efficiency for Sustainable Agriculture. AgriEngineering , 7 (4), 106. https://doi.org/10.3390/agriengineering7040106

Alvim, S.; Guimarães, C.; Sousa, E.; Garcia, R.; Marciano, C. (2022). Application of Artificial Intelligence for Irrigation Management: A Systematic Review. Engenharia. Agrícola, 42. https://doi.org/10.1590/1809-4430-eng.agric.v42nepe20210159/2022

Barreda Marín, A. (2025). Informe de las problemáticas políticas y sociales que ha enfrentado la red en la lucha por atender los problemas socioambientales. Primer encuentro de la Red Nacional de Pueblos Envenenados en Resistencia. https://www.youtube.com/watch?v=IveUQp51Vo8

Chen, W., Xu, D., Pan, B., Zhao, Y. y Song, Y. (2024). Machine Learning-Based Water Quality Classification Assessment. Water , 16 (20), 2951. https://doi.org/10.3390/w16202951

Chow, V. T., Maidment, D. R. y Mays, L. W. (1988). Applied Hydrology. McGraw-Hill, New York. https://wecivilengineers.wordpress.com/wp-content/uploads/2017/10/applied-hydrology-ven-te-chow.pdf

Shen, C. (2018). A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. Water Resources Research, 54(11), 8558–8593. https://doi.org/10.1029/2018WR022643

Takeda, T., Kato, J., Matsumura, T., Murakami, T., & Abeynayaka, A. (2021). Governance of Artificial Intelligence in Water and Wastewater Management: The Case Study of Japan. Hydrology, 8(3), 120. https://doi.org/10.3390/hydrology8030120

Taloma, R.J.L., Cuomo, F., Comminiello, D. et al. Machine learning for smart water distribution systems: exploring applications, challenges and future perspectives. Artif Intell Rev 58, 120 (2025). https://doi.org/10.1007/s10462-024-11093-7

WWAP (World Water Assessment Programme). (2022). The United Nations World Water Development Report 2022: Groundwater: Making the invisible visible. UNESCO, París. https://www.unesco.org/reports/wwdr/2022/en/download

INTELIGENCIA ARTIFICIAL PARA LA GESTIÓN DE EVENTOS HIDROMETEOROLÓGICOS EN REGIONES ALTAMENTE VULNERABLES

LAURA CONDE BÁEZ, CUAUHTÉMOC F. PINEDA MUÑOZ
Facultad de Ciencias Químico Biológicas,
Universidad Autónoma de Guerrero (UAGro)

JOSÉ ALFREDO PINEDA GÓMEZ
Facultad de Ciencias de la Educación, Maestría en Economía Social,
Universidad Autónoma de Guerrero (UAGro)

ARTÍCULO

Resumen

En las últimas dos décadas, la frecuencia de eventos hidrometeorológicos extremos ha aumentado más del 80% a nivel global, afectando principalmente a regiones con alta vulnerabilidad socioambiental. Solo en 2023, más de 340 millones de personas fueron impactadas por inundaciones, huracanes y sequías, generando pérdidas superiores a 250 mil millones de dólares. Este artículo analiza el papel de la inteligencia artificial (IA) en la predicción y gestión de estos eventos, destacando su potencial para fortalecer los sistemas de alerta temprana y apoyar la toma de decisiones en contextos con infraestructura limitada.

Introducción

El cambio climático está intensificando de forma acelerada los eventos hidrometeorológicos extremos: entre el año 2000 y 2019 se registraron más de 6,600 eventos de este tipo en el mundo, casi el doble que en las dos décadas anteriores (UNDRR-CRED, 2020). Huracanes de categoría 4 y 5, precipitaciones torrenciales e intensas olas de calor están remodelando los ecosistemas, desplazando poblaciones y colapsando infraestructuras críticas. Las regiones más afectadas por el cambio climático son, preocupantemente, aquellas con menor capacidad de respuesta: se estima que el 93 % de los desastres climá-

ticos ocurren en países en desarrollo, donde más del 50 % de la población carece de acceso a sistemas de alerta temprana eficaces (WMO, 2023).

En este escenario, la inteligencia artificial (IA) se perfila como una herramienta de alto impacto. Al analizar millones de datos en tiempo real, detectar patrones ocultos y anticipar escenarios críticos, la IA puede revolucionar la forma en que enfrentamos los riesgos climáticos. Por ejemplo, modelos de aprendizaje profundo han demostrado ser hasta 30 % más precisos que los métodos tradicionales para predecir inundaciones en cuencas no monitoreadas (Nearing et al., 2023). En este artículo se analizan las aplicaciones emergentes de la IA en la gestión de eventos extremos, con énfasis en territorios donde convergen la vulnerabilidad climática, la exclusión digital y la desigualdad estructural.

Inteligencia artificial y eventos extremos

La inteligencia artificial abarca un conjunto de técnicas computacionales, entre las que destacan las redes neuronales artificiales (ANN, por sus siglas en inglés: Artificial Neural Network), los algoritmos de aprendizaje profundo (deep learning) y los modelos de árboles de decisión. Estos sistemas pueden entrenarse con datos históricos y en tiempo real para anticipar fenómenos extremos, identificar zonas de riesgo y emitir alertas tempranas con mayor precisión, que los modelos estadísticos tradicionales.

En India, por ejemplo, la Comisión Central del Agua y Google desarrollaron e implementaron sistemas de alerta temprana para inundaciones urbanas mediante modelos de aprendizaje automático (Google, 2020; Jain & Khatri, 2021); en Bangladesh, la IA se combina con sensores remotos para pronosticar ciclones y mareas de tormenta (Alam & Rahman, 2021). En Estados Unidos, la Administración Nacional Oceánica y Atmosférica (NOAA) y la NASA emplean redes neuronales para mejorar el seguimiento de huracanes, sequías e incendios forestales (NOAA, 2023; Rasp & Dueben, 2020), destacando su uso en California para estimar la propagación de incendios mediante datos satelitales en tiempo real (Xu et al., 2022). En Europa, Italia ha implementado modelos basados en IA para predecir deslizamientos en zonas alpinas (Segoni et al., 2018), y

en América Latina, Brasil aplica estas tecnologías para prevenir lluvias extremas y deslaves en ciudades como Río de Janeiro (Oliveira et al., 2021). En México, los estudios emergentes exploran la predicción de tormentas en cuencas del Golfo de México y el uso de técnicas de nowcasting para lluvias intensas (Martínez & Cervantes, 2020; Raga et al., 2021). Estos avances dependen de la disponibilidad de datos históricos y satelitales, infraestructura tecnológica, cooperación institucional y, en contextos rurales, la integración del conocimiento local con los sistemas de alerta automatizados deberían ser una práctica a considerar.

Vulnerabilidad y exposición al riesgo climático

En contextos altamente vulnerables al cambio climático —marcados por exposición geográfica, infraestructura deficiente, escasa conectividad digital y pobreza estructural—la inteligencia artificial (IA) está emergiendo como una herramienta prometedora para fortalecer los sistemas de alerta temprana, incluso en ausencia de redes de monitoreo tradicionales. Estudios recientes demuestran que modelos de bajo costo, como los desarrollados por el Alan Turing Institute (The Guardian, 2025), permiten realizar pronósticos metereológicos localizados utilizando únicamente una computadora portátil. En paralelo, Google AI ha implementado un sistema operativo en más de 80 países en desarrollo, que utiliza datos satelitales y aprendizaje automático para predecir inundaciones en cuencas no monitoreadas con hasta cinco días de anticipación (Nearing et al., 2023).

Otras investigaciones muestran que, en zonas urbanas sin sensores formales, es posible generar alertas en tiempo real mediante análisis de datos ciudadanos y redes sociales (Pathak et al., 2023). Además, se han diseñado sistemas basados en sensores loT de bajo costo y redes neuronales de grafos para monitorear lluvias intensas en áreas rurales sin estaciones meteorológicas (Lee et al., 2024). Plataformas como PRISM, impulsadas por el Programa Mundial de Alimentos, también han sido fundamentales al integrar información climática, social y geoespacial para mapear riesgos en territorios de escasos recursos (WFP, 2024). En conjunto, estas iniciativas demuestran que la IA puede adaptarse

a condiciones de alta vulnerabilidad si se prioriza el uso de datos abiertos, tecnologías apropiadas y enfoques territorializados.

Aplicaciones de la IA para la reducción del riesgo climático y agrícola

La inteligencia artificial (IA) se ha consolidado como una herramienta clave para anticipar y mitigar riesgos climáticos y agrícolas en contextos vulnerables. Un estudio de 2025 desarrolló un sistema de IA explicable (XAI) basado en modelos secuenciales BiLSTM, que incorpora mecanismos como TimeSHAP (Véase Figura 1) para interpretar predicciones y anticipar eventos como heladas, inundaciones, sequías y granizadas, mejorando la precisión y la confianza en la toma de decisiones (Zheng & Chu, 2025). Investigaciones adicionales evidencian que modelos integrados con datos meteorológicos, geoespaciales y socioeconómicos generan alertas más localizadas y oportunas (Reichstein et al., 2025), mientras que algoritmos como los de Nearing et al. (2023) amplían el acceso a pronósticos en más de 80 países en desarrollo. Estas aplicaciones optimizan recursos, fortalecen la planificación y reducen pérdidas humanas, materiales y productivas (Bari et al., 2023).

Figura 1. Representación del marco unificado de pronóstico multirriesgo para la agricultura, que integra datos meteorológicos, un modelo secuencial con atención y el enfoque de explicabilidad TimeSHAP para generar explicaciones locales y globales. Adaptada de Zheng & Chu (2025), bajo licencia CC BY 4.0.

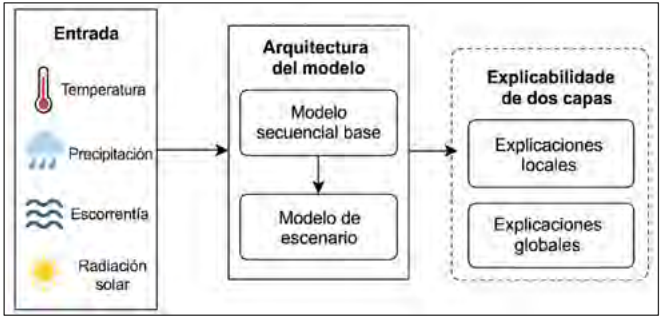

Retos y recomendaciones para su implementación

La implementación de sistemas predictivos basados en inteligencia artificial (IA) en contextos de alta

vulnerabilidad climática enfrenta múltiples desafíos estructurales, técnicos y socioculturales. Entre los principales retos que reducirían esta brecha se encuentran:

- *Infraestructura digital limitada,* que impide la transmisión o procesamiento de datos en tiempo real.
- *Escasa disponibilidad de datos locales,* lo cual dificulta el entrenamiento y validación de modelos predictivos con pertinencia territorial.
- *Baja formación técnica,* tanto en instituciones como en comunidades lo que limita la apropiación y operación autónoma de las herramientas.
- *Fragmentación institucional y escasa interoperabilidad* entre actores técnicos, políticos y comunitarios.
- *Desconfianza o resistencia sociocultural* frente a tecnologías percibidas como externas o incomprensibles.

Frente a estos desafíos, se recomienda avanzar mediante proyectos piloto en territorios estratégicos que integren desde el inicio a gobiernos locales, instituciones académicas y organizaciones comunitarias.

Conclusiones

La IA representa una herramienta prometedora para anticipar y gestionar eventos hidrometeorológicos extremos, especialmente en regiones vulnerables donde los sistemas de monitoreo tradicionales son insuficientes. Su aplicación puede mejorar la capacidad de respuesta, reducir los impactos humanos y materiales, y fortalecer las estrategias de adaptación al cambio climático. No obstante, su efectividad requiere voluntad política, articulación institucional, inversión en capacidades locales y enfoques participativos.

Bibliografía

Abid, S. K. (2021). How artificial intelligence can boost disaster management. Sustainability, 13(22), 12560. https://doi.org/10.3390/su132212560

Alam, M., & Rahman, M. (2021). Machine learning-based early warning system for tropical cyclones in Bangladesh. Journal of Coastal Research, 114(sp1), 174–180.

Bari, L. F., Imran, M., & Ahmed, A. (2023). Potential use of artificial intelligence in disaster risk management: Optimizing logistics and response. Journal of Disaster Research, 18(2), 97–109.

Camps-Valls, G., Reichstein, M., & Zhu, X. X. (2025). Transparency and explainability in climate AI. Nature Climate Change, 15(1), 12–19.

Ghaffarian, S., Farahani, R. Z., & Asgari, N. (2023). Explainable artificial intelligence in disaster risk management: A systematic review. Risk Analysis, 43(5), 1002–1018.

Google. (2020). Using AI to predict floods in India. Google AI Blog. https://ai.googleblog.com/2020/06/using-ai-to-predict-floods-in-india.html

Jain, S., & Khatri, N. (2021). Flood forecasting using machine learning and satellite data in India. Remote Sensing, 13(14), 2734. https://doi.org/10.3390/rs13142734

Lee, J., Kim, H., & Park, S. (2024). Low-cost IoT rainfall monitoring and short-term prediction using graph neural networks. arXiv preprint, arXiv:2412.16842.

Martínez, M. A., & Cervantes, A. (2020). Aplicación de redes neuronales artificiales en la predicción de precipitaciones en el Golfo de México. Revista Mexicana de Ciencias Geológicas, 37(2), 270–283.

Nearing, G. S., Kratzert, F., et al. (2023). AI increases global access to reliable flood forecasts in ungauged basins. Nature, 627, 559–563. https://doi.org/10.1038/s41586-024-07145-1

NOAA. (2023). Artificial intelligence strategy. U.S. Department of Commerce. https://www.noaa.gov/ai

Oliveira, L. F., et al. (2021). Use of machine learning for rainfall-induced landslide prediction in urban areas: A case study in Rio de Janeiro. Natural Hazards, 106, 2543–2565.

Pathak, A., Jaiswal, R., & Kumar, N. (2023). Social sensing for real-time flood mapping in urban India using Twitter data. arXiv preprint, arXiv:2306.09770.

Raga, G. B., et al. (2021). Nowcasting precipitation using satellite and radar data in southeastern Mexico. Atmospheric Research, 247, 105189. https://doi.org/10.1016/j.atmosres.2020.105189

Rasp, S., & Dueben, P. D. (2020). WeatherBench: A benchmark dataset for data-driven weather forecasting. Journal of Advances in Modeling Earth Systems, 12(11), e2020MS002203.

Reichstein, M., Han, B., Camps-Valls, G., et al. (2025). Early warning of complex climate risk with integrated artificial intelligence. Nature Communications, 16, 2564. https://doi.org/10.1038/s41467-025-57640-w

Segoni, S., et al. (2018). Landslide susceptibility mapping using artificial neural networks and geospatial data in the northern Apennines. Environmental Earth Sciences, 77, 507.

UNDRR & CRED. (2020). The human cost of disasters: An overview of the last 20 years 2000–2019. https://www.undrr.org/publication/human-cost-disasters-overview-last-20-years-2000-2019

WFP. (2024). Platform for Real-time Impact and Situation Monitoring (PRISM). World Food Programme. https://www.wfp.org/publications/prism-platform-real-time-impact-and-situation-monitoring

WMO. (2023). Global annual to decadal climate update. World Meteorological Organization. https://public.wmo.int/en/resources/bulletin

Xu, W., et al. (2022). Deep-learning-based wildfire spread prediction with real-time satellite data in California. Natural Hazards, 111, 345–368.

Zheng, Y., & Chu, X. (2025). Explainable AI for multi-hazard early warning systems in agriculture. arXiv preprint, arXiv:2507.22962. https://arxiv.org/abs/2507.22962

DISTRIBUCIÓN GUMBEL Y ANÁLISIS DE LLUVIAS EXTREMAS: IMPLEMENTACIÓN COMPUTACIONAL ASISTIDA POR IA

MARGARITA PRECIADO, RODRIGO ROBLERO-HIDALGO
Instituto Mexicano de Tecnología del Agua

MARITZA ARGANIS
Facultad de Ingeniería e Instituto de Ingeniería, UNAM

ARTÍCULO

Resumen

En esta investigación se sintetiza el uso de la distribución Gumbel para el análisis de frecuencias de lluvias máximas anuales. Se abordan los fundamentos teóricos basados en la Teoría de Valores Extremos, los métodos de estimación de parámetros como el Método de los Momentos (MOM), Máxima Verosimilitud (MVE) y su implementación mediante herramientas computacionales. En particular, se resalta el papel de la inteligencia artificial IA, específicamente DeepSeek, en el desarrollo del programa Gumbel.exe en lenguaje Python, lo que permitió automatizar procesos, optimizar cálculos y acelerar la generación de resultados con alta precisión. Esta integración de IA representa un avance significativo en la eficiencia, accesibilidad y reproducibilidad de los análisis hidrológicos. Así mismo, se discute la interpretación del periodo de retorno y su relevancia en el diseño de infraestructura hidráulica También se analizan las ventajas y limitaciones de la distribución Gumbel, incluyendo su aplicabilidad en contextos de cambio climático. El artículo destaca la importancia de una selección adecuada del modelo estadístico para una gestión hídrica eficiente y resiliente, y propone la incorporación de tecnologías emergentes como la inteligencia artificial como una vía prometedora para fortalecer la toma de decisio-

nes en el ámbito hidrológico.

1. Introducción

El análisis de eventos hidrológicos extremos, como las lluvias máximas anuales, es fundamental para el diseño de infraestructuras hidráulicas y la gestión de riesgos. La distribución Gumbel, derivada de la Teoría de Valores Extremos, permite modelar estos eventos raros con base en registros históricos limitados. Su aplicación en hidrología ha sido ampliamente aceptada por su simplicidad y capacidad para representar valores extremos. La distribución Gumbel ha sido ampliamente utilizada para modelar eventos hidrológicos extremos (Gumbel, 1958), especialmente en el análisis de lluvias máximas anuales.

2. Metodología y Desarrollo

La distribución Gumbel se caracteriza por dos parámetros: ubicación (μ) y escala (β), los cuales determinan la forma y posición de la función de distribución acumulada de una variable aleatoria x (ecuación 1).

$$F(x) = \exp(-\exp(-(x - \mu)/\beta)) \quad (1)$$

Para estimar estos parámetros, se emplean el Método de los Momentos (MOM), basado en la media y desviación estándar de los datos, y la Máxima Verosimilitud (MLE), que ofrece mayor precisión estadística, especialmente con muestras pequeñas. Los métodos de estimación como el Método de los Momentos y la Máxima Verosimilitud han demostrado ser efectivos en estudios hidrológicos previos (Chow, Maidment & Mays, 1988). La guía del Ministerio de Ambiente de Argentina (2019) ofrece lineamientos para el análisis de crecidas que fueron considerados al validar la metodología aplicada.

Además, Loaiciga et al. (2004) discuten cómo la distribución Gumbel puede caracterizar fenómenos extremos de manera robusta en diferentes contextos hidrológicos.

El análisis de frecuencias requiere construir series de máximos anuales y aplicar la distribución para estimar lluvias asociadas a distintos periodos de retorno. El periodo de retorno (T), en años se

relaciona con la probabilidad de excedencia (P=1-F(x)) mediante la ecuación 2.

$$T = 1/P \quad (2)$$

Esta métrica es esencial para dimensionar obras hidráulicas según su nivel de riesgo aceptable

3. Implementación Computacional

Para la implementación computacional, se utilizaron librerías como scipy.stats.gumbel_r en Python (SciPy, n.d.), evd en R (RDocumentation, n.d.) y funciones de distribución de valores extremos en MATLAB (MathWorks, n.d.), lo cual facilitó la automatización y precisión en los cálculos. Estas herramientas facilitan la estimación de parámetros, simulación de eventos extremos y generación de curvas de frecuencia. Entre las ventajas de la distribución Gumbel destacan su simplicidad, amplia aceptación y capacidad para modelar colas pesadas. Sin embargo, presenta limitaciones como su rigidez para representar diferentes asimetrías y la posible subestimación de eventos extremadamente grandes. Además, suponer estacionariedad en los datos puede ser problemático en contextos de cambio climático, por lo que se recomienda considerar modelos más flexibles como la distribución Generalizada de Valores Extremos (GEV) o enfoques no estacionarios.

Además, es importante destacar que la integración de la distribución Gumbel con modelos hidrológicos de simulación permite una evaluación más robusta de escenarios futuros bajo condiciones de incertidumbre.

Esta integración se vuelve especialmente relevante en el contexto de la planificación adaptativa, donde las decisiones deben tomarse considerando múltiples trayectorias posibles del clima y del uso del suelo. La capacidad de la distribución Gumbel para proporcionar estimaciones probabilísticas de eventos extremos la convierte en una herramienta clave para alimentar modelos de riesgo y vulnerabilidad, facilitando así la priorización de inversiones en infraestructura y medidas de mitigación. Asimismo, su uso en combinación con técnicas de análisis multivariado y sistemas de información geográfica (SIG) abre nuevas posibilidades para la identificación de zonas críticas y la formulación de políticas públicas basadas en evidencia cuantitativa.

En este sentido, la distribución Gumbel no solo representa un instrumento estadístico, sino también un componente esencial de una estrategia integral de gestión del riesgo hidrológico en el siglo XXI.

En este trabajo se presenta el programa Gumbel.exe, desarrollado en lenguaje Python con el apoyo de la inteligencia artificial DeepSeek. Este software integra una interfaz gráfica intuitiva basada en Tkinter y ttkbootstrap, permitiendo al usuario:

- Estimar parámetros estadísticos
- Calcular periodos de retorno
- Generar visualizaciones comparativas entre datos observados y curvas teóricas

Su diseño modular incluye secciones informativas sobre fundamentos teóricos, metodología, aplicaciones prácticas y referencias bibliográficas, convirtiéndolo en una herramienta integral para investigadores, profesionales del agua y tomadores de decisiones. El presente programa constituye una herramienta computacional especializada para el análisis estadístico de eventos extremos hidrológicos, enfocada particularmente en el estudio de lluvias máximas anuales mediante la distribución de Gumbel. La integración de Gumbel con modelos hidrológicos de simulación permite evaluar escenarios futuros bajo incertidumbre, siendo clave en la planificación adaptativa. Su uso combinado con análisis multivariado y sistemas de información geográfica (SIG) abre nuevas posibilidades para identificar zonas críticas y formular políticas públicas basadas en evidencia cuantitativa. En las Figuras 1 a 8 se ilustra la interfaz del programa, así como los principales menús de entrada y salida de resultados e información.

5. Conclusiones

La distribución Gumbel constituye una herramienta valiosa para el análisis de lluvias máximas anuales en hidrología. Su implementación mediante métodos estadísticos y herramientas computacionales permite estimar eventos extremos con base en registros históricos. No obstante, su aplicación debe considerar las limitaciones del modelo, especialmente en escenarios de no-estacionariedad. La comparación con otras distribuciones y la validación mediante pruebas de bondad de ajuste son

Figura 1. Ventana de lectura de datos anuales. Programa Gumbel.exe

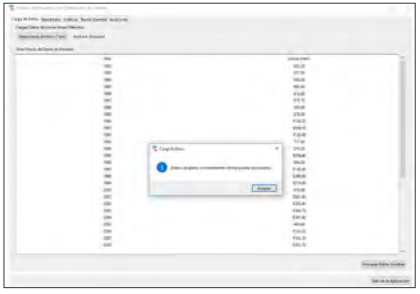

Figura 2. Ventana de resultados del cálculo de eventos de diseño para distintos periodos de retorno, en años. Programa Gumbel.exe

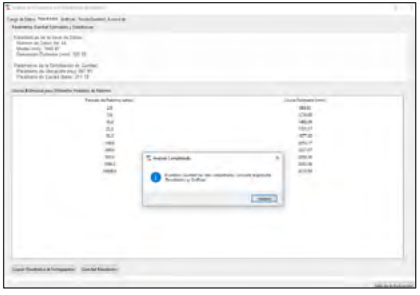

Figura 3. Ventana de representación de los datos medidos y calculados con la función de distribución Gumbel, parámetros obtenidos por el método de Momentos. Programa Gumbel.exe

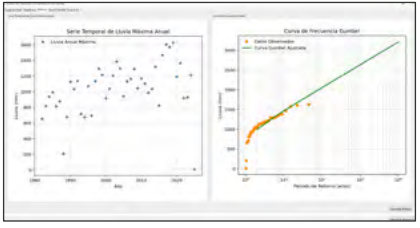

Figura 4. Ventana de información de la Teoría Gumbel, Fundamentos teóricos. Programa Gumbel.exe

Figura 5. Ventana de información de la Teoría Gumbel, Metodología. Programa Gumbel.exe

Figura 6. Ventana de información de la Teoría Gumbel, Aplicaciones. Programa Gumbel.exe

Figura 7. Ventana de información de la Teoría Gumbel, Referencias. Programa Gumbel.exe

Figura 8. Ventana de información de Acerca de. Programa Gumbel.exe

esenciales para garantizar la fiabilidad de los resultados. Una selección adecuada del modelo estadístico contribuye a un diseño hidráulico más seguro y eficiente.

En síntesis, la distribución Gumbel no solo representa una herramienta estadística robusta, sino que también constituye un puente entre la teoría hidrológica y la toma de decisiones prácticas. Su implementación en plataformas computacionales ha democratizado su uso, permitiendo que profesionales de distintas disciplinas puedan acceder a análisis de frecuencia con mayor precisión. En este contexto, el desarrollo del programa Gumbel.exe en lenguaje Python, apoyado por la inteligencia artificial DeepSeek, ejemplifica cómo la incorporación de tecnologías emergentes puede transformar radicalmente los procesos de análisis hidrológico. DeepSeek no solo facilitó la generación de código eficiente y funcional, sino que también permitió automatizar tareas complejas, optimizar algoritmos y reducir significativamente los tiempos de desarrollo. Esta sinergia entre programación y IA representa un avance hacia una hidrología computacional más accesible, precisa y reproducible, donde el conocimiento técnico se complementa con capacidades inteligentes para acelerar la toma de decisiones. El uso de la IA demuestra cómo la inteligencia artificial puede

actuar como un catalizador en la democratización del análisis estadístico, permitiendo a investigadores y profesionales abordar problemas hidrológicos con mayor agilidad y profundidad. No obstante, se recomienda complementar su aplicación con otras distribuciones cuando se detecten sesgos significativos en los datos o cuando se requiera una mayor flexibilidad en el modelado de colas extremas. La integración de enfoques probabilísticos con herramientas de simulación hidrológica representa una línea prometedora para futuras investigaciones.

Bibliografía

Gumbel, E. J. (1958). Statistics of extremes. Columbia University Press.

Chow, V. T., Maidment, D. R., & Mays, L. W. (1988). Applied hydrology. McGraw-Hill.

Ministerio de Ambiente de Argentina. (2019). Guía para el análisis de frecuencias de crecidas. https://www.argentina.gob.ar/sites/default/files/guia_frecuencia_crecidas_2019.pdf

Loaiciga, H. A., et al. (2004). The Gumbel distribution in extreme hydrologic characterization. Journal of Flood Engineering.

SciPy. (n.d.). scipy.stats.gumbel_r. https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.gumbel_r.html

RDocumentation. (n.d.). evd package. https://rdocumentation.org/packages/evd

MathWorks. (n.d.). Extreme value distribution in MATLAB. https://www.mathworks.com/help/stats/extreme-value-distribution.html

PREDICCIÓN DE VARIABLES HIDROCLIMÁTICAS MEDIANTE MÉTODOS ESTADÍSTICOS E INTELIGENCIA ARTIFICIAL

MICAELA CARMEN QUISBERT MORILLAS Y
JOSÉ LUIS ARAGÓN-HERNÁNDEZ
Facultad de Ingeniería, UNAM
Grupo de Enseñanza e Investigación en Ingeniería y Ciencias del Agua (GEIICA)

ARTÍCULO

Resumen

Se evalúan distintos métodos para completar datos faltantes en series de tiempo de caudales medios anuales. Se aplicaron enfoques de regresión estadística, interpolación y redes neuronales artificiales. La eficiencia de cada método se analiza mediante correlación cruzada, eliminando datos individuales y consecutivos a lo largo de la serie. Los resultados indican que las técnicas basadas en Inteligencia Artificial ofrecen estimaciones más precisas, alcanzando coeficientes de determinación superiores a 0.95. Para el entrenamiento de estos modelos se consideraron variables hidroclimáticas. Estas metodologías representan herramientas robustas para mejorar la falta de información hidrométrica, y fortalecer la gestión de recursos hídricos en cuencas con registros de datos hidroclimáticos incompletos.

Introducción

La Inteligencia Artificial (IA) es el campo que busca desarrollar sistemas capaces de imitar habilidades humanas como el razonamiento, el aprendizaje y la toma de decisiones (Hassan et al., 2022, pág. 280). Dentro de ella se encuentra el aprendizaje automático (*Machine Learning, ML*) y el aprendizaje profundo (*Deep Learning, DL*) véase Figura 1.

Figura 1. Inteligencia artificial, aprendizaje automático y aprendizaje profundo

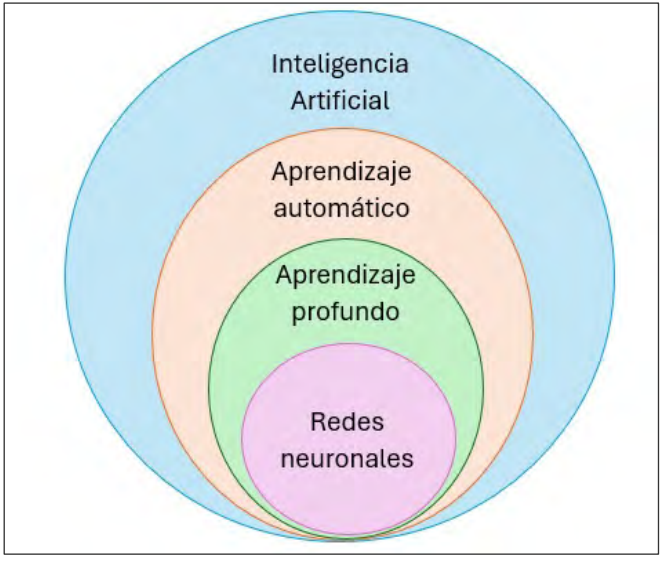

La IA se ha aplicado en diversos campos (Sotomayor, 2001, págs. 1-2), entre ellos la hidrología, en el cual, uno de los modelos de IA más utilizados son las redes neuronales artificiales, RNA (Hassan et al., 2022, págs. 281-282).

Las RNA son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas (Polo et al., 2015, pág. 89). Una RNA consta de una capa de entrada, capa(s) oculta(s), y una capa de salida. Cada capa incluye varias unidades llamadas neuronas. El funcionamiento general de forma simplificada inicia con las entradas que recibe una neurona, enseguida se realiza una suma ponderada, luego pasa por una función de activación, y finalmente se produce una salida. Cada neurona tiene un vector de pesos, así como un sesgo que debe optimizarse (Chahal & Gulia, 2019, pág. 4913), véase Figura 2.

Las RNA pueden clasificarse según su arquitectura, distinguiéndose: RNA de propagación hacia adelante (*feed-forward*), RNA convolucionales, y RNA recurrentes (Makosso et al., 2024, pág. 1).

Las RNA han demostrado ser una herramienta adecuada para los problemas de modelado en series de tiempo, entre ellas, las hidroclimáticas (precipitación, temperatura, caudal, etc.), ofreciendo un enfoque eficaz en el manejo de grandes

Figura 2. Estructura de una neurona artificial (mejorado de Chahal & Gulia, 2019, pág. 4913)

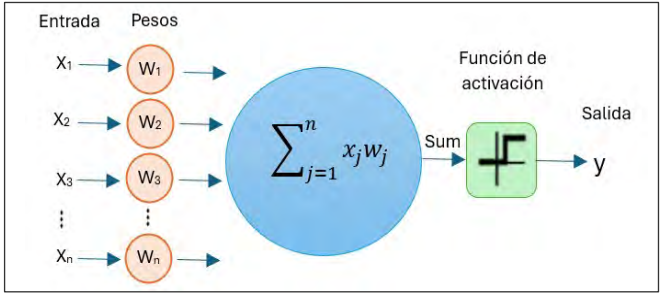

cantidades de datos dinámicos, no lineales y con presencia de ruidos (Muñoz et al., 2020, pág. 3).

Por otra parte, es importante disponer con registros de caudales medidos en estaciones hidrométricas (EH), con el fin de que cualquier estudio hidrológico se sustente de un registro confiable y dentro de lo posible, sin interrupciones en el tiempo (Quevedo, 2021, pág. 1).

Lamentablemente, las EH no disponen de series continuas. Esta deficiencia se debe a varios factores, entre ellos la ausencia temporal de personal, mal funcionamiento de los equipos de medición, falta de recursos financieros, entre otros (Mwale et al., 2012, pág. 34).

Si bien, los métodos tradicionales han sido de gran ayuda, en los últimos años, para completar datos faltantes en series de tiempo hidroclimáticas, se han propuesto modelos más eficientes, y con mayor exactitud en la predicción (Agudelo-Otálora et al., 2020, pág. 212). Sin embargo, la técnica más adecuada dependerá de la longitud de los registros, longitud de vacíos y disponibilidad de datos de apoyo en estaciones cercanas (Mwale et al., 2012, pág. 34).

La regresión estadística es uno de los métodos más utilizados debido a su fácil aplicación, aunque una correlación adecuada entre las variables implicadas no siempre se cumple (Mwale et al., 2012, pág. 35). En cambio, los métodos de interpolación como Spline Cúbico y Pchip, son funciones formadas por secciones de polinomios cúbicos, que se enlazan con la mayor suavidad posible a través de los datos (Durán, 1994, pág. 30). En la actualidad, las técnicas de IA han llegado para revolucionar el análisis de datos a largo plazo y a gran escala, en parte, gracias a su capacidad de hacer predicciones preci-

sas con pocos insumos (Hassan et al., 2022, pág. 280).

Este trabajo se enfoca en la reconstrucción de series temporales de caudal medio anual en la cuenca del río Jamapa-Cotaxtla, implementando técnicas estadísticas (regresión lineal), métodos de interpolación (Pchip y Spline cúbico), y redes neuronales de propagación hacia adelante (feed-forward, FF) y recurrentes (LSTM).

Desarrollo

La cuenca del río Jamapa-Cotaxtla se localiza en el estado de Veracruz-México, entre los paralelos 18° 44' y 19° 15' de latitud norte, y los meridianos 95° 56' y 97° 16' longitud oeste, abarcando una superficie aproximada de 3,962 Km^2; cuenta con dos afluentes importantes: el río Jamapa y el río Cotaxtla (adaptado de CONAGUA, 2024, pág. 2)

Para el análisis, se utilizaron 4 EH (una fuera de la cuenca) y una estación climatológica, véase tabla 1 y figura 3.

Nombre	Clave	Tipo	Latitud	Longitud
El Tejar	B28040	Hidrométrica	19° 4.1'N	96° 9.6'O
Paso del Toro	B28039	Hidrométrica	19° 2.5'N	96° 8.4'O
El Copital	C30048	Climatológica	18° 58.0'N	96° 12.3'O
Capulines	B28069	Hidrométrica	18° 51.9'N	96° 18.3'O
Cardel	B28003	Hidrométrica	19° 21.7'N	96° 22.4'O

Tabla 1. Datos generales de las estaciones hidrométricas y climatológica

Se obtuvieron los registros de caudal medio anual de cada EH (Base datos CONAGUA); véase en la figura 4 los registros de la EH bajo análisis.

Para evaluar la eficacia de las distintas técnicas para completar datos faltantes, se realizaron pruebas controladas mediante correlación cruzada (suposición de datos existentes). En una primera etapa, mediante la eliminación de tres datos faltantes individuales (1D). Posteriormente, dos datos consecutivos (2D), con el fin de observar el desempeño de las técnicas ante vacíos continuos. Finalmente, se repitió el procedimiento eliminando tres datos consecutivos (3D), lo que repre-

Figura 3. Ubicación de la cuenca del río Jamapa-Cotaxtla (Quisbert & Aragón-Hernández, 2025, pág. 3)

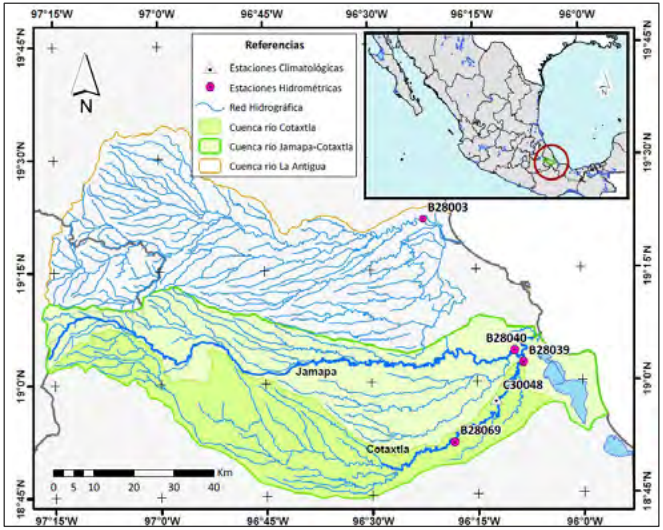

senta un escenario aún más desafiante para la estimación. En los tres casos, los supuestos faltantes, se consideraron distribuidos a lo largo del periodo histórico (aproximadamente a ¼, ½ y ¾ de la longitud del registro).

Figura 4. Serie continua de datos de caudal medio anual EH: B28039

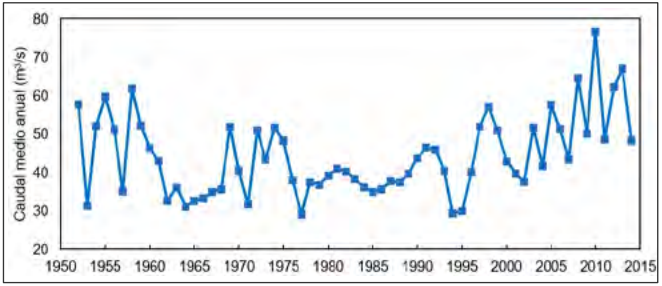

Los métodos evaluados se agruparon bajo cuatro enfoques principales: M1, basados en regresión lineal utilizando información de EH cercanas (a: misma corriente, EH B28069; b: otra corriente, pero misma cuenca, EH B28040 y c: otra cuenca, EH B28003); M2, mediante interpolación (a: Pchip y b: spline cúbico); y M3, mediante el uso de RNA (a: FF y b: LSTM). Para el entrenamiento de las RNA se consideraron datos de precipitación media anual en la estación climatológica C30048 y; además, datos de temperatura solo para el caso M3a. Cada uno de estos métodos fue aplicado a los distintos

Figura 5. Serie de caudales medios anuales completados: 1D, 2D y 3D, respectivamente

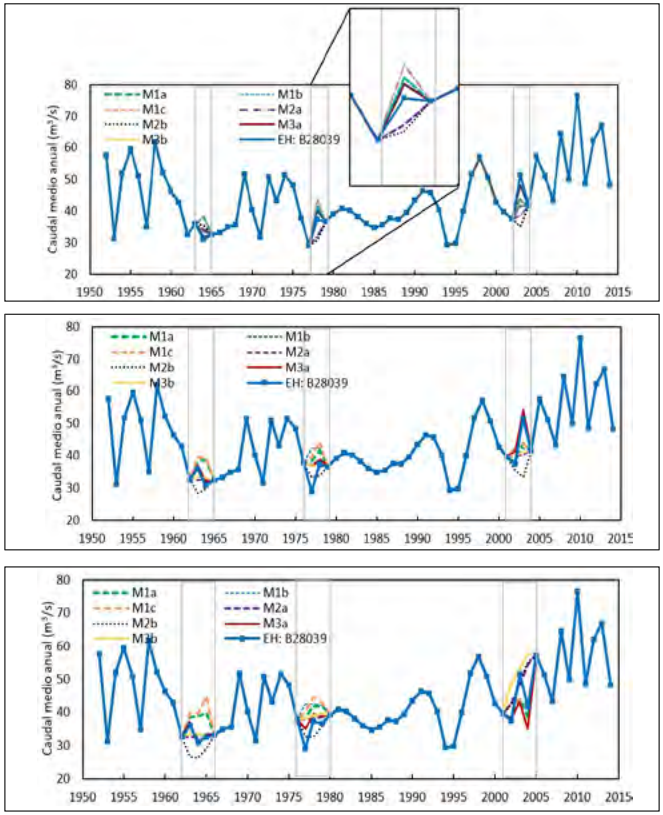

escenarios de datos faltantes propuestos (1D, 2D y 3D); los resultados obtenidos, fueron comparados con los datos medidos para determinar su desempeño en la reconstrucción de series de caudales (véase figura 5).

Para evaluar el desempeño de las técnicas aplicadas, se realizó un análisis numérico mediante una representación gráfica de la comparación entre valores medidos y estimados (véase figura 6).

Los coeficientes de determinación obtenidos de mayor valor (R2=0.96 y R2=0.98) corresponden a los métodos de RNA (M3a y M3b, respectivamente), lo que evidencia su alta capacidad predictiva.

Conclusiones

La aplicación de las distintas técnicas permitió la reconstrucción de series de caudales medios anuales. Los métodos de interpolación presentaron un desempeño pobre (R2<0.29); la actuación de los métodos estadísticos fue mejor, pero la correlación no siempre se cumple, como con la EH B2801 (M1b); en cambio, los métodos basados en las RNA, entrenadas con variables climatológicas puntuales (precipitación y

Figura 6. Caudales medidos y estimados: Regresión lineal, interpolación y RNA

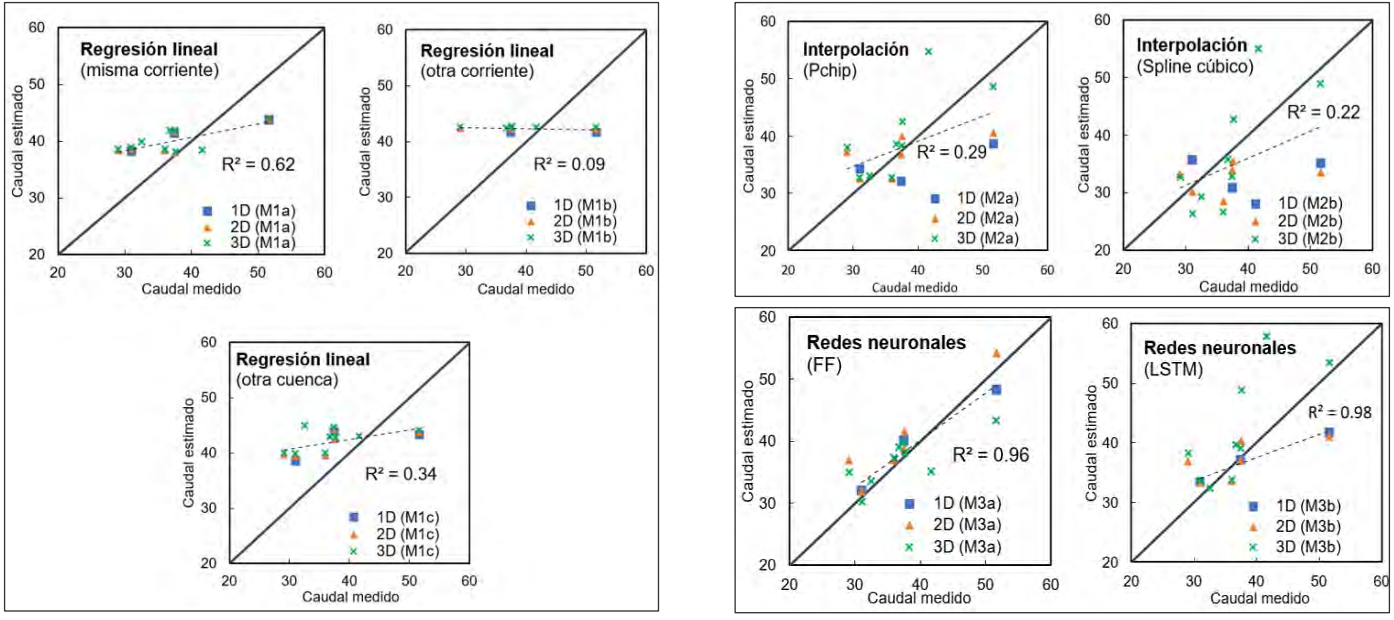

temperatura), mejoraron y por mucho, la precisión en la estimación de datos faltantes (R2>0.96).

No obstante, se recomienda para estudios futuros, incorporar más variables hidroclimáticas y la física de los fenómenos hidrológicos involucrados en el proceso lluvia-escurrimiento; además de evaluar el desempeño de los modelos en resoluciones

temporales más detalladas, como series mensuales o incluso diarias y horarias.

Bibliografía

Agudelo-Otálora, L., Moscoso-Barrera, W., Paipa-Galeano, L., & Mesa-Sciarrotta, C. (2020). Comparación de modelos físicos y de inteligencia artificial para predicción de niveles de inundación. Tecnología y ciencias del agua, Vol.9, 209-236.

Chahal, A., & Gulia, P. (2019). Machine Learning and Deep Learning. International Journal of Innovative Technology and Exploring Engineering (IJITEE), Vol.8, 4910-4914.

CONAGUA. (2024). Actualización de la disponibilidad media anual de agua en el acuífero Cotaxtla (3008), Estado de Veracruz. Gerencia de aguas subterráneas. Ciudad de México.

Durán, C. (1994). Interpolación y suavizamiento con Splines. Universidad Nacional Autónoma de México.

Hassan, K., Feng, Y., Najah, A., Hoon, C., & El-Shafie, A. (2022). A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forcasting. Alexandria Engineering Journal, 61, 279-303.

Makosso, T., Almaktoof, A., & Abo-Al-Ez, K. (2024). Review of Different Types of Neural Network Architectures. International Journal of Electrical Engineering and Applied Sciences (IJEEAS), Vol.7.

Muñoz, W., Bedoya, O., & Rincón, M. (2020). Aplicación de redes neuronales para la reconstrucción de series de tiempo de precipitación y temperatura utilizando información satelital. RevistaEIA, Vol.17, 1-16.

Mwale, F., Adeloye, A., & Rustum, R. (2012). Infilling of missing rainfall and streamflow data in the Shire River basin, Malawi - A self organizing map approach. Physics and Chemistry of the Earth, 34-43.

Polo, D., Pedraza, L., & Martinez, E. (2015). Comparación de Redes Neuronales aplicadas a la predicción de Series de tiempo. Prospect, Vol 13, 88-95.

Quevedo, M. (2021). Metodología para el relleno de registros fluviométricos diarios en cuencas chilenas cercanas al régimen natural. Santiago de Chile: Universidad de Chile.

Quisbert, M., & Aragón-Hernández, J.L. (2025). Predicción y comparación de variables hidroclimáticas mediante distintos métodos. Jornadas de Ingeniería del Agua, Zaragoza, España (aceptado).

Sotomayor, J. (2001). La inteligencia artificial y su aplicación en diversos sectores productivos. Investigación Administrativa, 1-6.

PREDICCIÓN DE SEQUÍAS CON INTELIGENCIA ARTIFICIAL: HERRAMIENTAS, TENDENCIAS Y DESAFÍOS ACTUALES

BRENDA ARACELY RAMÍREZ-BARRAZA,
ENRIQUE ÁVILA-SOLER
Universidad Autónoma Metropolitana- Azcapotzalco

ARTÍCULO

Resumen

Las sequías, cada vez más frecuentes e intensas, plantean un serio desafío para garantizar el acceso al agua. Este artículo analiza cómo la inteligencia artificial (IA) se ha convertido en una herramienta clave para anticipar estos fenómenos con mayor precisión. Mediante redes neuronales, modelos híbridos y aprendizaje automático que procesan grandes volúmenes de datos climáticos, hoy es posible prever sequías con meses de antelación. Se presentan casos en México, China, India y otros países, donde estas tecnologías apoyan la toma de decisiones. También se examinan los retos que enfrentan: escasez de datos, complejidad de los modelos y riesgo de exclusión de comunidades vulnerables. Usada de forma adecuada, la IA puede fortalecer la gestión hídrica, impulsar la equidad y mejorar la resiliencia frente a sequías futuras.

Introducción

¿Sabías que la inteligencia artificial (IA) ya está ayudando a predecir sequías con una precisión sin precedentes? Gracias a su capacidad para procesar grandes volúmenes de datos climáticos y generar pronósticos más fiables, la IA se ha convertido en una herramienta clave para anticipar y mitigar los impactos de estos fenómenos en sectores como la

agricultura, el abastecimiento de agua y la seguridad alimentaria. Las sequías, caracterizadas por una escasez prolongada de agua, pueden clasificarse en meteorológicas, hidrológicas, agrícolas y socioeconómicas, cada una con efectos específicos(Mishra y Singh, 2010; Wilhite y Glantz, 1985). En el contexto de cambio climático, su frecuencia e intensidad se han aumentado, haciendo indispensable desarrollar sistemas de predicción confiables. En este escenario, la IA abre nuevas oportunidades, ya que, mediante el análisis masivo de datos, es capaz de anticipar con mayor precisión las condiciones que podrían desencadenar sequías. Este artículo revisa estudios recientes sobre su aplicación en México y otros países, analizando herramientas, tendencias y desafíos, con el objetivo de mostrar su potencial como apoyo en la toma de decisiones frente a uno de los desafíos ambientales más críticos: sequías.

Desarrollo

Herramientas

Entre las principales herramientas empleadas con IA destacan:

Las Redes Neuronales Artificiales (ANN): Modelos que imitan el funcionamiento del cerebro humano y se especializan en reconocer patrones complejos, como precipitación, temperatura, humedad o presión atmosférica (Ortiz Domínguez, 2025).

La Máquina de Soporte Vectorial (SVM): efectiva incluso con pocos datos y útil para delimitar con precisión la frontera entre condiciones de presencia o ausencia de sequía (Poudel et al., 2024).

Los Modelos Híbridos, que combinan técnicas de preprocesamiento de datos, como la transformada wavelet (WPTT), seguida de aprendizaje automático. Este enfoque ha demostrado mejorar la exactitud para pronósticos de 3–6 meses, al capturar patrones multiescala en series temporales(Mohammadi et al., 2025).

Estudios destacados

En México, Esquivel-Saenz et al. (2024) aplicaron ANN en el estado de Zacatecas, utilizando 52 años de datos de temperatura y precipitación para predecir tres índices: índice de precipitación estandarizado (SPI), el índice de precipitación-evapotranspiración

estandarizado (SPEI) y el índice de déficit de lluvia (RDI). El RDI fue el que mejor se ajustó a los datos con 83%.

Hernández-Vásquez et al. (2022) aplicaron ANN en la cuenca del río Sonora para predecir SPI y SPEI en escalas temporales de 3 a 24 meses, con una precisión promedio del 76 %.

A nivel internacional, diversos estudios han demostrado la eficacia de modelos avanzados en la predicción de sequías. En Shaanxi, China, Zhang et al. (2019) compararon tres métodos y hallaron que los árboles de decisión mejorados como (XGBoost) fue el más preciso, con aciertos del 89 % al 97 % y capacidad de anticipar sequías hasta con seis meses de antelación. En la India, Wable et al. (2023) encontraron que el modelo híbrido Wavelet-Bootstrap-ANN fue más eficiente para prever el SPEI a 12 meses, destacando por su baja incertidumbre y alta precisión. En Irán, Morid et al. (2007) demostraron que las redes neuronales superan a los modelos estadísticos tradicionales en la predicción del SPI . De forma similar, en Malasia, Khan et al. (2018) desarrollaron el modelo híbrido Wavelet-ANN, que mejoró de forma notable el desempeño de las ANN convencionales, alcanzando correlaciones superiores a 0.96.

Tendencias

Tres tendencias clave destacan en la predicción de sequías con IA

1. Modelos híbridos, que combinan técnicas de aprendizaje automático como redes neuronales o máquinas de soporte vectorial con métodos avanzados de procesamiento de series temporales como la transformada wavelet. Estos modelos han demostrado mejorar significativamente la precisión en pronósticos a mediano plazo (Alawsi et al., 2022).
2. Inteligencia Artificial Explicable (XAI), para comprender cómo opera un modelo en todo un conjunto de datos, resaltar las variables que son generalmente significativas y revelar las tendencias generales del modelo; se centra en casos específicos, esclareciendo por qué el modelo realizó una determinada

predicción y qué variables influyeron en esa decisión (Ozupek et al., 2025).

3. Integración de datos diversos y en tiempo real, con el uso de imágenes satelitales con modelos como EarthFormer (Marusov et al., 2024).

Desafíos

Entre los desafíos más significativos destacan la calidad de la información, la interpretación de los modelos y el uso ético y equitativo de la IA.

En cuanto a la calidad de la información se presenta la limitada disponibilidad de datos ya que muchas estaciones meteorológicas presentan registros discontinuos, y la integración de datos satelitales, de sensores remotos o tecnologías de monitoreo conectadas a internet aún es parcial e inconsistente, lo que limita la precisión y cobertura espacial de los modelos predictivos (Camps-Valls et al., 2025).

La interpretación de los modelos depende de la complejidad de estos. Las técnicas de cuantificación de incertidumbre, como los intervalos de confianza y las predicciones probabilísticas, ayudan a los responsables de políticas a evaluar la fiabilidad de las proyecciones climáticas generadas por IA (McGovern et al., 2017).

Finalmente, el uso ético y equitativo de la IA en la predicción de sequías requiere atención; es necesario que las comunidades rurales y pequeños productores no queden excluidos del acceso a estas tecnologías, y que los datos utilizados no reproduzcan sesgos ni generen desigualdades en la distribución del agua o la atención al riesgo (Amnuaylojaroen, 2025).

Conclusiones

La IA puede anticipar sequías con meses de antelación y transformar la gestión del agua hacia una mayor eficiencia, equidad y resiliencia. Modelos como Wavelet-Bootstrap ANN están revolucionando las predicciones, mejorando la precisión y estimando la incertidumbre, clave para decisiones seguras. Pronósticos confiables permiten a gobiernos, agricultores y comunidades prepararse y reducir pérdidas económicas y daños ambientales. Sistemas de alerta

temprana precisos y planificación hídrica adaptativa pueden mitigar los impactos de estos fenómenos.

Para maximizar su potencial, se requiere inversión tecnológica, capacitación institucional y gobernanza hídrica que fomente la cooperación entre actores.

¿Estamos listos para tomar decisiones antes de que falte el agua? La inteligencia artificial puede ser la herramienta necesaria para adelantarnos a la próxima sequía, pero su efectividad dependerá de la capacidad para integrarla estratégicamente en las políticas públicas y la cultura de gestión del agua.

Bibliografía

Alawsi, M. A., Zubaidi, S. L., Al-Bdairi, N. S. S., Al-Ansari, N., & Hashim, K. (2022). Drought Forecasting: A Review and Assessment of the Hybrid Techniques and Data Pre-Processing. Hydrology, 9(7), 115. https://doi.org/10.3390/hydrology9070115

Amnuaylojaroen, T. (2025). Advancements and challenges of artificial intelligence in climate modeling for sustainable urban planning. Frontiers in Artificial Intelligence, 8. https://doi.org/10.3389/frai.2025.1517986

Camps-Valls, G., Fernández-Torres, M.-Á., Cohrs, K.-H., Höhl, A., Castelletti, A., Pacal, A., Robin, C., Martinuzzi, F., Papoutsis, I., Prapas, I., Pérez-Aracil, J., Weigel, K., Gonzalez-Calabuig, M., Reichstein, M., Rabel, M., Giuliani, M., Mahecha, M. D., Popescu, O.-I., Pellicer-Valero, O. J., ... Williams, T. (2025). Artificial intelligence for modeling and understanding extreme weather and climate events. Nature Communications, 16(1), 1919. https://doi.org/10.1038/s41467-025-56573-8

Esquivel-Saenz, P. J., Ortiz-Gómez, R., Zavala, M., & Flowers-Cano, R. S. (2024). Artificial Neural Networks for Drought Forecasting in the Central Region of the State of Zacatecas, Mexico. Climate, 12(9), 131. https://doi.org/10.3390/cli12090131

Hernández-Vásquez, C. C., Ibáñez-Castillo, L. A., Arteaga-Ramírez, R., Monterroso-Rivas, A. I., & Cervantes-Osornio, R. (2022). Pronóstico de sequías meteorológicas usando redes neuronales artificiales en la cuenca del río Sonora, México. Tecnología y Ciencias Del Agua, 13(3), 242–292. https://doi.org/10.24850/j-tyca-2022-03-06

Marusov, A., Grabar, V., Maximov, Y., Sotiriadi, N., Bulkin, A., & Zaytsev, A. (2024). Long-term drought prediction using deep neural networks based on geospatial weather data. Environmental Modelling & Software, 179, 1–27.

McGovern, A., Elmore, K. L., Gagne, D. J., Haupt, S. E., Karstens, C. D., Lagerquist, R., Smith, T., & Williams, J. K. (2017). Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather. Bulletin of the American Meteorological Society, 98(10), 2073–2090. https://doi.org/10.1175/BAMS-D-16-0123.1

Mishra, A. K., & Singh, V. P. (2010). A review of drought concepts. Journal of Hydrology, 391(1–2), 202–216. https://doi.org/10.1016/j.jhydrol.2010.07.012

Mohammadi, B., Abdallah, M., Oucheikh, R., Katipoğlu, O. M., & Cheraghalizadeh, M. (2025). Enhancing streamflow drought prediction: integrating wavelet decomposition with deep learning and quantile regression neural network models. Earth Science Informatics, 18(2), 232. https://doi.org/10.1007/s12145-025-01736-w

Morid, S., Smakhtin, V., & Bagherzadeh, K. (2007). Drought forecasting using artificial neural networks and time series of drought indices. International Journal of Climatology, 27(15), 2103–2111. https://doi.org/10.1002/joc.1498

Ortiz Domínguez, M. (2025). Redes neuronales artificiales. Ingenio y Conciencia Boletín Científico de La Escuela Superior Ciudad Sahagún, 12(23), 38–44. https://doi.org/10.29057/escs.v12i23.14132

Ozupek, E., Teke, A., Celik, N., & Kavzoglu, T. (2025). Explainable artificial intelligence to explore the intrinsic characteristics of climatic parameters governing meteorological drought forecasting: opening the black box. Stochastic Environmental Research and Risk Assessment. https://doi.org/10.1007/s00477-025-03007-y

Poudel, B., Dahal, D., Banjara, M., & Kalra, A. (2024). Assessing Meteorological Drought Patterns and Forecasting Accuracy with SPI and SPEI Using Machine Learning Models. Forecasting, 6(4), 1026–1044. https://doi.org/10.3390/forecast6040051

Wable, P. S., Jha, M. K., Adamala, S., Tiwari, M. K., & Biswal, S. (2023). Application of Hybrid ANN Techniques for Drought Forecasting in the Semi-Arid Region of India. Environmental Monitoring and Assessment, 195(9), 1090. https://doi.org/10.1007/s10661-023-11631-w

Wilhite, D. A., & Glantz, M. H. (1985). Understanding: the Drought Phenomenon: The Role of Definitions. Water International, 10(3), 111–120. https://doi.org/10.1080/02508068508686328

Zhang, R., Chen, Z.-Y., Xu, L.-J., & Ou, C.-Q. (2019). Meteorological drought forecasting based on a statistical model with machine learning techniques in Shaanxi province, China. Science of The Total Environment, 665, 338–346. https://doi.org/10.1016/j.scitotenv.2019.01.431

CAPACIDAD AUTÓNOMA DE LA INTELIGENCIA ARTIFICIAL PARA DILUCIDAR VARIACIONES DEL COMPORTAMIENTO HIDROLÓGICO EN UN PAISAJE CÁRSTICO

ISRAEL MEDINA-GÓMEZ
ENES-UNAM, Unidad Mérida

DIDIER OMAR GAMBOA ANGULO
Universidad Politécnica de Yucatán

ARTÍCULO

Resumen

La inteligencia artificial (IA) alienta una interacción coordinada de grupos diversos, que para la gestión de recursos hídricos, pudieran estar conformados por científicos de datos, expertos en geociencias, geohidrólogos, y especialistas en IA. La riqueza de equipos compuestos se refleja en la eficiencia para el diseño de alternativas realistas, encaminadas a la solución de problemas de los que suele adolecer el agua en las sociedades y sus ciudades. El uso de IA es relevante para abordar la evolución de eventos hidrometeorológicos que incidan en el almacenamiento del acuífero y mitigar su impacto negativo. La creciente capacidad de predicción del conjunto de tecnologías que integra la IA está cimentada en el carácter "data-driven" que alberga el cómputo de sus modelos. El beneficio de la IA transciende a distintas esferas del conocimiento, con un papel prominente en la supervisión de la calidad datos, la eficiencia operacional y capacidad de respuesta.

Introducción

Transcurre un período promisorio en lo que al análisis de datos concierne, y el campo de las geociencias no es ajeno a ello. Las posibilidades para colectar

observaciones de diferentes esferas de la Tierra, incluyendo la hidrósfera, han ido siendo procuradas en tiempos recientes con un talante más democrático, mediante plataformas de cómputo en la nube accesibles o bien, repositorios públicos, al tiempo que procedimientos diseñados en el ámbito de la ciencia de datos permiten recabar de manera eficiente y autónoma distintos rasgos relevantes (features) de procesos funcionales para detección en busca de patrones dentro del ciclo hidrológico.

Los principios físico-ambientales que rigen la disponibilidad del agua subterránea como recurso para los ecosistemas naturales y sine qua non para desarrollo de las sociedades constituyen un conjunto de elementos cuyas interacciones, retroalimentación, umbrales y comportamiento no-lineal requieren de un estudio acucioso que delinee sus trayectorias ante diversos escenarios de uso.

Con este panorama en mente, destaca la IA por su formidable capacidad para navegar a través de extensas matrices de datos e identificar patrones recurrentes y con ello, establecer correspondencias entre variables aparentemente inconexas. Asimismo, este conjunto de técnicas articula la colaboración de expertos dentro de la ingeniería y diversas áreas de la ciencia, así como también diletantes con el interés en la dinámica y constricciones del manto acuífero (almacenamiento en el freático).

Como en muchos terrenos donde la sociedad y academia se entrecruzan, la adopción de la IA como una tecnología naciente que apoye el desarrollo de la sociedades modernas depende de generar una masa crítica en el uso acertado de sus métodos analíticos e interpretación. El presente trabajo pretende contribuir al impulso de esta transición hacia una tecnología madura, usando como caso de estudio al acuífero de Yucatán, el cual provee una gama de servicios requeridos por nuestras comunidades, más allá del radicalmente importante aprovisionamiento de agua per se, pero incluye también aquellos a favor de los ecosistemas naturales, de cuya integridad dependen éstas.

Desarrollo

Con un espejo de agua dispuesto a ~5 m y escaso relieve, la Península de Yucatán es un terreno cuajado

de fracturas, encarnado por poljes y dolinas en el estrato rocoso. Este paisaje evoca la proclividad de la plataforma calcárea a su disolución, a la cual subyace una gran capacidad de infiltración que podría sustentar la noción de una suficiencia del acuífero yucateco, por decirlo menos, apta como fuente de agua dulce ad libitum para la región y sus habitantes. No obstante, una mirada más crítica al asunto del agua y su disponibilidad presente y futura, revela de hecho la amenaza de potencial escasez del recurso, en cantidad y calidad, que se cierne sobre el entorno yucateco. Esta condición es derivada del trato que se ha dispensado al mosaico de ecosistemas, en lo general desatento, no obstante constituye el soporte del ciclo hidrológico de esta región.

En virtud de las peculiaridades que caracterizan a los ambientes cársticos, en lo tocante a su permeabilidad y transmisividad específicamente, el manejo del agua está materializado por la gestión de diferentes componentes que modulan la proporción de recarga del acuífero, tales como la cobertura de vegetación como áreas filtrantes naturales, por lo cual los cambios que reflejen éstos como producto de estrategias de desarrollo son de interés, y el procesamiento de imágenes por IA brinda herramientas para su monitoreo.

Al explotar sus avanzadas técnicas automatizadas de reconocimiento e identificación de rasgos, así como clasificación precisa de patrones en escenas de amplia extensión superficial en función del tiempo, la IA hace posible la detección de objetos y sus variaciones, incluso los más sutiles, habilitando con ello un seguimiento pormenorizado de tendencias en procesos dinámicos relevantes, particularmente aquellos con el potencial de disrupción del ciclo del agua: expansión de mancha urbana, fragmentación del hábitat, desfasamiento ecológico, entre otros. La capacidad de albergar un análisis con contexto espacial y temporalidad de la IA ayuda a diseñar y recomendar acciones concretas sobre la base de esa información, que informe la toma de decisiones de cara a un uso sustentable.

Adquisición de data

En la actualidad existe una amplia gama de fuentes de datos que nos provee información sobre

componentes relevantes del ciclo del agua, y este acervo pudiera complementar series de datos in-situ, aunque éstas últimas permanecen usualmente limitadas en cuanto a su accesibilidad. Asimismo, información geoespacial accesoria proveniente de diferentes agencias como las que se enlistan a continuación, permiten contextualizar aquellas mediciones sobre la variable de interés (almacenamiento de agua por ejemplo):

1. CHIRPS à Para evaluar cambios en el gradiente regional de lluvias en ambientes donde el acuífero está controlado por la recarga meteórica.
2. GLDAS; MASCON à patrones de variación del nivel de acuíferos e implicaciones para la integridad de reservas hidrológicas.
3. LANDSAT à anomalías del estado de salud de la vegetación y detección de tendencias potencialmente perniciosas para el equilibrio ecológico de nuestras ciudades y el ciclo hidrológico.

Las plataformas de cómputo en la nube recientemente disponibles, como Google Earth Engine, proponen un acceso sin precedentes a un espléndido acervo de datos públicos de distinta naturaleza (espectro óptico y bandas de radar) con un nivel de resolución variable, tanto espacial como temporal.

Análisis de data

Los indicios que apuntan hacia una aproximación progresiva de puntos de inflexión en la naturaleza (pérdida de biodiversidad, remplazo de especies clave como depredadores o ensambles de comunidades bacterianas en suelos, al igual que alteración de cadenas tróficas) son el reflejo de un deterioro paulatino y el efecto acumulativo de pulsos en forzamientos climáticos, o físico-ambientales, tras los cual puede generarse un impacto agudo que desencadene un comportamiento de desfasamiento ecológico difícil de revertir, no obstante se suspenda la perturbación o forzamiento que lo detonó en primera instancia. El abastecimiento de agua juega un papel prominente en estas trayectorias ecológicas y vislumbrar cómo el comportamiento dinámico del nivel del manto acuífero se conecta con dichos mecanismos en estado temprano, antes de que se es-

tablezcan cambios asociados o incluso surjan síntomas inequívoco en los ecosistemas, es un cometido que la IA puede apuntalar.

Almacenamiento de data

Avances recientes en métodos de análisis de datos, como el aprendizaje automático (machine learning), proveen herramientas que permiten encarar la necesidad cada vez más urgente de resolver problemas reales y pertinentes de nuestro entorno, en virtud de la capacidad de dichas técnicas analíticas de coaligar diferentes áreas de la ciencia como matemáticas, biología, física o química.

En la era de la accesibilidad a datos geoespaciales referida anteriormente y métodos de análisis imbuidos con una constante actualización en la rama de ciencia de datos e IA aplicada al manejo de dicho torrente de datos, es posible abordar el seguimiento de procesos dinámicos en tiempo real a través de sistemas de gestión de cómputo flexible y escalable (cloud-based computing), y desvelar aspectos esclarecedores de la dinámica del almacenamiento en los acuíferos. (Véase Figura 1)

Figura 1. Esquema general de una plataforma de monitoreo integrada con IA para analisis y visualizacion del nivel del agua subterranea en tiempo real para acuifero no-confinado

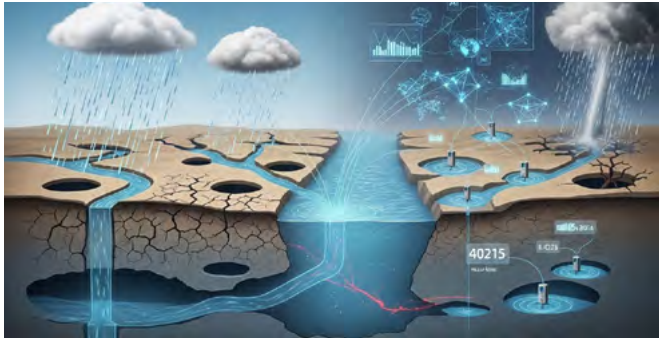

Conclusión

En un entorno de cambios rápidos impulsados por el desarrollo antropogénico, con capacidad desproporcionada de alterar ciclos fundamentales, es perentorio adelantarse a avizorar eventos que, ya sea aislados o compuestos, resulten en lluvias extremas, sequías prolongadas, o el desfasamiento de vegetación, y vislumbrar sus implicaciones en el almacenamiento de agua del manto acuífero. Dicha perspectiva se beneficiará en postular una hoja de

ruta con el uso de modelos de IA en consideración, y anticipar con ello en fase temprana de los proyectos, qué variables son clave en los proyectos de investigación sobre agua, implementando métodos efectivos para recabar datos selectos que sean útiles en el contexto de técnicas de IA. En síntesis, la adopción de la IA impacta positivamente no solo la consecución de los objetivos trazados por el proyecto, sino también nos permite avanzar en asegurar equilibrio para nuestras sociedades.

Bibliografía

Reinecke, Robert; Stein, Lina; Gnann, Sebastian; Andersson, Jafet; Arheimer, Berit; Bierkens, Marc; Bonetti, Sara; Güntner, Andreas; Kollet, Stefan; Mishra, Sulagna; Moosdorf, Nils; Nazari, Sara; Pokhrel, Yadu; Prudhomme, Christel; Schewe, Jacob; Shen, Chaopeng; Wagener, Thorsten; 2025. Uncertainties as a Guide for Global Water Model Advancement. Wiley Interdisciplinary Reviews: Water: 12:e70025. DOI: 10.31223/X56H8G.

Smerdon and Drewes 2017. Groundwater recharge: The intersection between humanity and hydrogeology. Journal of Hydrology 555 (2017) 909–911. https://doi.org/10.1016/j.jhydrol.2017.10.075

El Universal 2019. https://www.eluniversal.com.mx/techbit/qualcomm-usa-tecnologia-para-mejorar-la-calidad-del-agua-potable-en-merida/

QUALCOMM 2019. https://www.qualcomm.com/content/dam/qcomm-martech/dm-assets/documents/qua0168_12062019_cs_mexicodimeh20_spanish.pdf

DETECCIÓN BINARIA DE FUGAS EN REDES DE DISTRIBUCIÓN DE AGUA MEDIANTE XGBOOST: UN ENFOQUE BASADO EN IA

ELIZABETH PAULINE CARREÑO-ALVARADO
Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental – PPGERHA - UFPR

GILBERTO REYNOSO-MEZA
Programa Programa de Pós-graduação em Engenharia de Produção e Sistemas (PPGEPS), Pontifícia Universidade Católica do Paraná (PUCPR),

ARTÍCULO

Resumen

Sanidad, higiene y acceso al agua potable son derechos humanos fundamentales, sin embargo, hacerlos efectivos se ha vuelto un reto (BBVA Research, 2025). La degradación de las redes de distribución de agua a lo largo del tiempo debido a diversos factores ha aumentado las pérdidas de este recurso; además el crecimiento de la densidad de población aumenta la demanda, que a su vez aumenta las pérdidas. Todo esto lleva además de las pérdidas, a una deficiencia operacional, por ello es necesaria una gestión más eficiente por parte de los organismos de operación de agua. La inteligencia artificial, puede ser una herramienta de utilidad ya que cuenta con diferentes técnicas que pueden ayudar con el cometido. Hablaremos entonces de una técnica de machine learning: XGBoost y cómo puede su clasificación binaria ayudar en la detección de fugas, siendo usada en conjunto con el modelado hidráulico de redes de distribución de agua.

Introducción

Las redes de distribución tienen un papel importante en proveer agua potable para el consumo humano y actividades productivas. Sin embargo, las pérdidas

por fugas representan un desafío mundial con múltiples dimensiones: En México, en ciudades de todo el país, especialmente en áreas con infraestructura antigua, se registra una pérdida promedio del **40 % del agua**, debido al deterioro en los sistemas de distribución (El Sol de México, 2023). Otras evaluaciones elevan la pérdida hasta el **47 %** por fugas como promedio nacional (El País, 2023). En otros países como Brasil, los datos indican que la tasa de pérdidas en la distribución de agua (INO049) fue del 37.8% (SNIS-AE, 2022), ligeramente mejor que la registrada en 2018 de 37.06% o del 39.21% registrada en 2017.

Estas pérdidas no solo representan un desperdicio del recurso hídrico, conllevan también importantes costos energéticos asociados al bombeo y tratamiento de agua que no llega a los usuarios.

En este contexto, los avances recientes en Inteligencia Artificial (IA) ofrecen soluciones innovadoras por medio del aprendizaje automático Machine Learning, (ML) entre otros para monitoreo y detección temprana de anomalías (fugas) en redes hidráulicas. Las técnicas de clasificación binaria son un tipo de aprendizaje automático que predice entre **dos posibles categorías** (ej: “fuga” vs. “no fuga”). Éstas, han demostrado ser efectivas en la identificación de patrones asociados a fugas. El modelo analiza datos históricos aprende patrones y luego clasifica los nuevos datos en una de las dos clases. Su rendimiento se evalúa con métricas estándar de clasificación binaría.

Se trabajó con el algoritmo XGBoost (eXtreme Gradient Boosting), debido a su precisión en el manejo de datos estructurados y capacidad para manejar relaciones no lineales en sistemas complejos (Chen & Guestrin, 2016), EPANET y Phyton.

Metodología

Para trabajar con el modelo, se utilizaron los datos de referencia del repositorio LeakDB - desarrollado específicamente para la 1ª Conferencia Conjunta Internacional WDSA/CCWI 2018 – en conjunto con la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining), metodología estándar en ciencia de datos y Machine Learning (Schörer et al., 2021), mostrada en la Figura 1.

Figura 1 – Metodología CRISP-DM

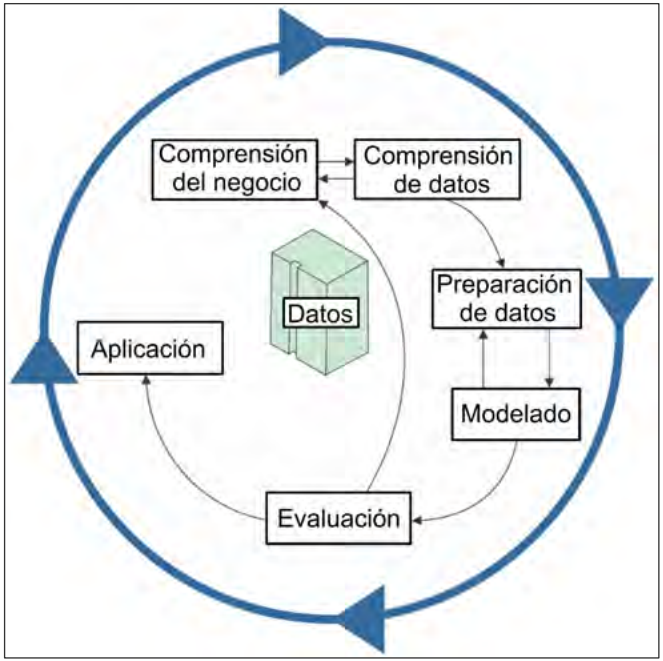

Este enfoque estructurado fue adaptado y aplicado en cuatro etapas relacionadas entre sí:

- **Etapa I: Comprensión del negocio, comprensión de datos y preparación de datos.** Fase inicial donde se realizó un análisis de requisitos operacionales. Se llevó a cabo la caracterización de los datos disponibles en la base de datos. Se generaron y preprocesaron datos hidráulicos. Se compilaron, verificaron y etiquetaron todos los conjuntos de datos de referencia.
- **Etapa II: Modelado y evaluación. Etapa de implementación y evaluación de modelos de aprendizaje automático.** El proceso fue iterativo, refinando continuamente la preparación de datos para optimizar el rendimiento del modelo. Se realizaron ajustes específicos para garantizar la calidad en los datos de entrada.
- **Etapa III: Reevaluación.** Esta fase consistió en un análisis crítico de los resultados obtenidos, para determinar si era necesario repetir o ajustar alguno de los pasos anteriores. Se prestó especial atención a la identificación de

posibles sesgos y al equilibrio entre complejidad del modelo y capacidad predictiva

- **Etapa IV: Preparación para la implementación.** La etapa final involucra la validación de los modelos con datos reales y la preparación de los protocolos necesarios para una eventual implementación operativa en sistemas de distribución reales.

El modelo XGBoost se eligío de tres modelos clásicos de aprendizaje automático: Random Forest (Bosques Aleatorios), XGBoost y K-Nearest Neighbors (KNN, Vecinos Más Cercanos); XGBoost se fundamenta en su equilibrio entre rendimiento predictivo e interpretabilidad de resultados, aspectos cruciales para aplicaciones en ingeniería hidráulica, destacando su combinación única de simplicidad conceptual, interpretabilidad de resultados y rendimiento predictivo, es un framework avanzado de "gradient boosting" que opera construyendo secuencialmente árboles de decisión, donde cada nuevo árbol corrige progresivamente los errores residuales de los anteriores.

Las ventajas técnicas clave incluyen:

- **Mecanismos de regularización integrados:** Control automático de la complejidad del modelo mediante penalizaciones L1/L2, L1 (Lasso) y L2 (Ridge) que previenen el sobreajuste (overfitting);
- **Robustez ante datos incompletos:** Capacidad nativa para manejar valores faltantes sin requerir preprocesamiento extensivo;
- **Eficiencia computacional:** Implementación optimizada que aprovecha el procesamiento paralelo y la memoria disponible;
- **Escalabilidad:** Capacidad para manejar grandes volúmenes de datos con requerimientos computacionales moderados;
- **Flexibilidad:** Soporte para múltiples funciones objetivo y métricas de evaluación personalizables.

El benchmark usado contiene 10 escenarios con características detalladas en la Tabla 1. Las simulaciones hidráulicas se realizaron en Python utilizando Anaconda, bibliotecas estándar, WNTR, EPyT para analisis de series temporales y EPANET.

Escenario	Fugas	Clasific. binaria	Nodo
1	No	0	
2	No	0	
3	Yes	1	19
3	Yes	1	26
4	No	0	
5	Yes	1	21
6	Yes	1	18
7	Yes	1	14
8	Yes	1	17
8	Yes	1	21
9	No	0	
10	Yes	1	12
10	Yes	1	28

Tabla 1 – Escenarios existentes en la base de datos

En cada simulación se consideró un período de tiempo de un año con intervalos de 30 minutos, con los datos obtenidos se construyó una base de datos que incluía, presiones, demandas y gastos, debidamente etiquetados y preparados para ser usados. Para simplificar la clasificación binaria (detección de fugas), se usó un subconjunto de siete escenarios cuidadosamente seleccionados: cuatro con condiciones normales de operación (sin fugas) y tres que incluían fuga, permitiendo generar doce combinaciones para los procesos de entrenamiento y validación cruzada, aplicando en todos los casos una división de datos 70/30% (entrenamiento/prueba), como muestra la tabla 2.

	Escenarios considerados						
Combinación	Entrenamiento					Prueba	
Combi_1	2	4	6	7	9	1	5
Combi_2	2	4	5	7	9	1	6
Combi_3	2	4	5	6	9	1	7
Combi_4	1	4	6	7	9	2	5
Combi_5	1	4	5	7	9	2	6
Combi_6	1	4	5	6	9	2	7
Combi_7	1	2	6	7	9	4	5
Combi_8	1	2	5	7	9	4	6
Combi_9	1	2	5	6	9	4	7
Combi_10	1	2	4	6	7	9	5
Combi_11	1	2	4	5	7	9	6
Combi_12	1	2	4	5	6	9	7

Sin Fuga | Con Fuga

Tabla 2 – Selección de escenarios entrenamiento, prueba

La preparación de datos incluyó:

1. **Extracción de características:** Selección de parámetros clave (presión, demanda, flujo) de cada escenario
2. **Etiquetado:** Asignación de clases binarias (1=fuga presente, 0=sin fuga) con verificación manual
3. **Normalización:** Estandarización de escalas para variables numéricas
4. **Partición:** División estratificada de conjuntos de entrenamiento y prueba

El procesamiento, modelado y análisis se implementó en Python utilizando el entorno de desarrollo Anaconda. Se emplearon bibliotecas estándar (NumPy, Pandas, Scikit-learn, etc.). El equipo usado tiene las siguientes especificaciones técnicas:

- Sistema Operativo: Windows 11 Pro
- Procesador: AMD Ryzen 5 5500U con gráficos Radeon integrados, 2.10 GHz (hasta 4.0 GHz en turbo), 6 núcleos físicos, 12 hilos lógicos
- Memoria RAM: 16 GB DDR4
- Almacenamiento: SSD NVMe 512 GB

El tiempo de entrenamiento fue de alrededor de 21 minutos, en cada iteración.

Resultados y Evaluación

El modelo fue evaluado utilizando las siguientes métricas estándar de clasificación binaría: exactitud (accuracy) que indica la proporción total de predicciones correctas o casos positivos; precisión (precision) que indica la capacidad del modelo para evitar falsas alarmas; la sensibilidad (Recall) o Tasa de Verdaderos Positivos, que cuantifica la capacidad del modelo para identificar correctamente todos los casos positivos relevantes. Un valor alto de sensibilidad indica una menor cantidad de falsos negativos (Powers, 2011). Calculando la proporción de verdaderos positivos correctamente identificados respecto al total de casos positivos reales es equivalente a detectar todas las fugas en una red hidráulica, finalmente la matriz de confusión es una representación tabular que contrasta las etiquetas reales con las predicciones del modelo. Esta matriz detalla cuatro categorías fundamentales:

- Verdaderos Positivos (TP): Casos positivos correctamente clasificados
- Falsos Positivos (FP): Casos negativos incorrectamente clasificados como positivos
- Verdaderos Negativos (TN): Casos negativos correctamente clasificados
- Falsos Negativos (FN): Casos positivos incorrectamente clasificados como negativos

El puntaje F1 que representa la media armónica entre la Precisión y la Sensibilidad, enfatizando el equilibrio entre ambas métricas es particularmente útil en situaciones con distribuciones de clases desbalanceadas. La Figura 3 muestra la matriz de confusión del modelo, mientras la Figura 2 muestra un gráfico resumen con las métricas evaluadas en las 12 configuraciones entrenamiento/prueba con XGBoost, teniendo dos configuraciones clave. Se enfatiza **F1** debido a su relevancia en la detección de fugas, donde tanto las **falsas alarmas (precisión)** como las **fugas no detectadas (sensibilidad)** tienen consecuencias operativas significativas.

Figura 2 – Matriz de confusión

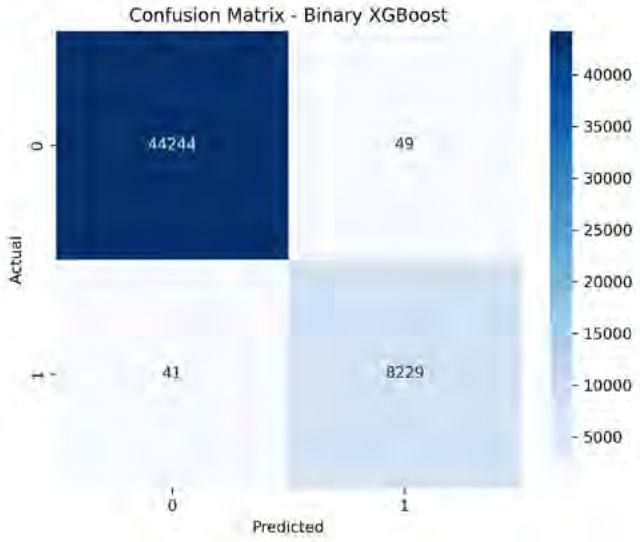

Figura 3 – Métricas evaluadas con XGBoost

Combi_1	XGBoost
Accuracy	0.66153
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_10	XGBoost
Accuracy	0.83076
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_11	XGBoost
Accuracy	0.95168
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_12	XGBoost
Accuracy	0.99683
Precision	0.93277
Recall	0.70032
F1_Score	0.8

Combi_9	XGBoost
Accuracy	0.99349
Precision	1.0
Recall	0.28076
F1_Score	0.43842

Combi_2	XGBoost
Accuracy	0.90428
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_3	XGBoost
Accuracy	0.996
Precision	1.0
Recall	0.77918
F1_Score	0.87589

Combi_4	XGBoost
Accuracy	0.83967
Precision	1.0
Recall	0.05261
F1_Score	0.09997

Combi_5	XGBoost
Accuracy	0.95214
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_6	XGBoost
Accuracy	0.99934
Precision	1.0
Recall	0.92744
F1_Score	0.96236

Combi_7	XGBoost
Accuracy	0.83028
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_8	XGBoost
Accuracy	0.95214
Precision	0.0
Recall	0.0
F1_Score	0.0

Combi_12: Precisión = 0.9968, F1-score = 0.8
Combi_6: F1-score = 0.9624

Figura 4 – Precisión del modelo de las diferentes combinaciones

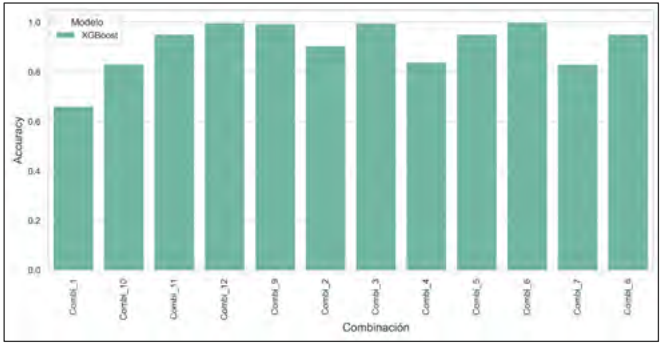

Figura 5 – F1 del modelo de las diferentes combinaciones

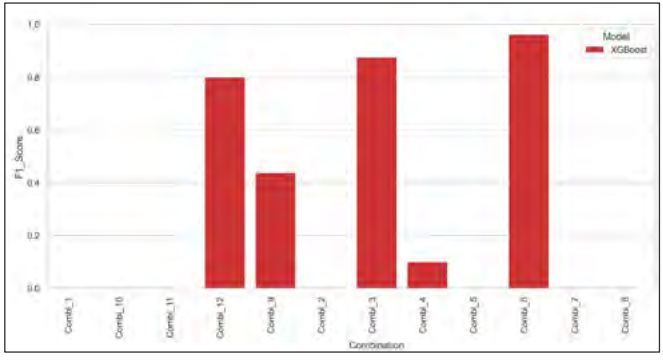

Discusión y Conclusiones

Se observa la aplicabilidad práctica XGBoost, técnica de IA/ML, para detección binaria de fugas en sistemas de distribución de agua. Concluyendo su capacidad para distinguir fuga/no fuga, incluso en escenarios complejos. Mostró robustez en las configuraciones de entrenamiento/prueba, adaptable a topologías de red. F1-score como métrica principal permitió optimizar el equilibrio crítico entre:

a. Falsas alarmas (costos operativos innecesarios)
b. Fugas no detectadas (pérdidas continuas de agua)

Los beneficios del uso de estas técnicas incluirían la reducción de pérdidas de una forma sostenible (detección temprana), se podrían optimizar recursos en programas de mantenimiento predictivo e integrarse con sistemas SCADA (nuevos o existentes) y una base de monitores inteligentes podría ser desarrollada. Para esto se requerirán datos, así, el problema reside primeramente en la instrumentalización de las redes de distribución de agua o digitalización, de acciones como incorporar datos reales a las redes operativas, colocación de sensores, adaptación de esquemas de clasificación de datos, integrar sistemas de georeferenciación para localización y desarrollo de interfaces visuales para facilitar los procesos, implicando mucho trabajo e inversión económica necesaria, así como continuar con la investigación a profundidad con la promesa de resultados que ayudarán a salvaguardar el recurso hídrico.

Bibliografía

BBVA Research. (2025). México: situación hídrica 2025. Disponível em: https://www.bbvaresearch.com/wp-content/uploads/2025/04/Mexico-situacion-hidrica-2025.pdf [Consultado el 01 de agosto de 2025].

Chen, T. e Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Nova York: ACM, pp. 785–794.

El País. (2023). México seco: las cifras ocultas de la carestía del agua. Disponível em: https://elpais.com/mexico/2023-08-21/mexico-seco-las-cifras-ocultas-de-la-carestia-del-agua.html [Consultado el 01 de agosto de 2025].

El Sol de México. (s.d.). Ciudades pierden el 40% de agua por viejos sistemas de distribución en México. OEM. Disponível em: https://oem.com.mx/elsoldemexico/mexico/ciudades-pierden-el-40-de-agua-por-viejos-sistemas-de-distribucion-en-mexico-15835997 [Consultado el 01 de agosto de 2025].

Powers, D.M.W. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. Journal of Machine Learning Technologies, 2(1), pp. 37–63.

Schröer, C., Kruse, F. e Gómez, J.M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. Procedia Computer Science, 181, pp. 526–534.

SNSA - Secretaria Nacional de Saneamento Ambiental e SNIS - Sistema Nacional de Informações sobre Saneamento. (2023). Diagnóstico Temático Serviços de Água e Esgoto; Visão Geral ano de referência 2022. Ministério das Cidades. Brasília.

Vrachimis, S.G., Kyriakou, M.S., Eliades, D.G. e Polycarpou, M.M. (2018). LeakDB: A Benchmark Dataset for Leakage Diagnosis in Water Distribution Networks. *In: 1st International WDSA / CCWI 2018 Joint Conference*. Kingston, Ontario, Canada.

INTERMITENCIA HÍDRICA, INTELIGENCIA ARTIFICIAL Y RESILIENCIA DEMOCRÁTICA

ANA JESSICA DÍAZ FIGUEROA
Museo Gota de Agua

JUAN JOSÉ SANTIBAÑEZ SANTIAGO
UAM-Iztapalapa/ Museo Gota de Agua

ARTÍCULO

Resumen

La intermitencia en el suministro de agua potable constituye un desafío estructural en gran parte del Sur Global, donde más de mil millones de personas dependen de un servicio discontinuo. Este fenómeno refleja fallas en la gobernanza, inequidades sociales y ausencia de políticas resilientes. El artículo propone replantear la intermitencia como una oportunidad estratégica para rediseñar sistemas más equitativos mediante el uso de inteligencia artificial (IA), en particular algoritmos bioinspirados en el comportamiento de colonias de hormigas.

A partir de evidencia en América Latina, Asia y África, y apoyado en marcos de autoorganización (Zhang, 2013), se desarrolla un modelo conceptual que combina eficiencia técnica, resiliencia ecológica y democracia hídrica. Se plantea que la política pública debe incorporar tarifas progresivas, simuladores comunitarios y esquemas de gobernanza multinivel. La intermitencia: laboratorio de innovación, no obstáculo estructural.

Introducción

La intermitencia en el suministro de agua potable es uno de los problemas más extendidos en las ciudades del Sur Global. Más de 1,000 millones de personas dependen de sistemas intermitentes (Bivins et al., 2017). Este fenómeno no significa sólo escasez física: expresa fallas en planeación, gobernanza y justicia social. Históricamente, la intermitencia se relaciona con urbanización acelerada sin inversiones proporcionales en infraestructura.

En muchas ciudades, las redes fueron diseñadas para poblaciones mucho menores y, actualmente, la sobreexplotación de acuíferos y el cambio climático han agravado la presión. Ante esto, el resultado es racionamiento, pérdida de confianza institucional y desigualdad en el acceso: mientras los ricos almacenan el agua en cisternas, los pobres dependen de pipas y pagan precios mucho más altos para poder abastecerse del vital líquido.

Este artículo parte de la hipótesis de que la intermitencia puede ser transformada en un espacio de innovación resiliente mediante la aplicación de la inteligencia artificial, en particular, los algoritmos de optimización por colonia de hormigas (ACO).

La intermitencia como síntoma estructural

Los estudios de caso muestran que la intermitencia es un síntoma de crisis institucional más que un fallo técnico aislado. En Tegucigalpa, la rotación de barrios en turnos de agua refleja precariedad operativa y politización de decisiones (Yepes et al., 2001). En Cisjordania, la intermitencia responde a factores geopolíticos y de control territorial (Vairavamoorthy et al., 2007). En Delhi, la estratificación social define quién accede a tanques privados y quién depende de camiones cisterna (Satpathy & Jha, 2022). En Kampala, la intermitencia se vincula con contaminación de acuíferos, al coexistir con saneamiento deficiente (Nyenje et al., 2021). En Panamá y Nueva Delhi, los estudios hidráulicos demostraron que los impactos no siempre corresponden a predicciones catastrofistas, lo que evidencia la variabilidad local (Erickson et al., 2022).

La intermitencia también es un fenómeno de género: en África Subsahariana, las mujeres dedi-

can entre 2 y 6 horas diarias a acarrear agua, con impacto en educación y empleo. En síntesis, la intermitencia refleja desigualdad social, fragilidad institucional y crisis de confianza.

Resiliencia y política pública

El marco SETS (socio–ecológico–tecnológico) permite entender la intermitencia como un reto integral:

- Desde lo social, muestra inequidades en capacidad de almacenamiento y acceso.
- Desde lo ecológico, revela sobreexplotación de fuentes y efectos del cambio climático.
- Desde lo tecnológico, expone redes obsoletas y pérdidas por fugas.

La resiliencia implica adaptabilidad institucional y cultural. Ostrom (1990) demostró que los bienes comunes pueden gestionarse colectivamente bajo reglas claras. En agua urbana, esto significa reconocer a los ciudadanos como co-gestores más que consumidores pasivos. Ejemplos recientes confirman esta visión: en Ciudad del Cabo, la amenaza del "Día Cero" redujo el consumo per cápita de 200 a 50 litros diarios mediante campañas colectivas y tarifas diferenciales. En São Paulo, la sequía de 2015 impulsó incentivos económicos para hogares que redujeran su consumo. Ambos casos muestran que la política pública puede orientar conductas hacia la corresponsabilidad.

Inteligencia artificial como oportunidad

La Inteligencia Artificial (IA) ha demostrado su capacidad en sectores críticos: en energía, gestiona redes inteligentes; en transporte, optimiza rutas y reduce tiempos; en agua, se aplica en predicción de fugas y calidad (Wu et al., 2020). Entre las técnicas más prometedoras destacan los algoritmos bioinspirados. La optimización por colonia de hormigas (ACO), desarrollada por Dorigo en los años noventa, simula cómo las hormigas eligen rutas eficientes mediante feromonas. Los caminos reforzados colectivamente se vuelven las rutas óptimas (Dorigo & Stützle, 2004).

Trasladado a sistemas intermitentes, los nodos serían fuentes, tanques y hogares; las tuberías, senderos; las feromonas, indicadores de presión

y confiabilidad. Con base en esta lógica, la red podría autoajustarse, favoreciendo la equidad en el reparto.

Metodología: Adaptación del ACO a redes intermitentes

Para robustecer la propuesta, se adopta el enfoque de autoorganización descrito por Zhang (2013), que muestra cómo los algoritmos bioinspirados se comportan como sistemas dinámicos estocásticos:

- Representación de la red: Los nodos equivalen a fuentes de agua, tanques y hogares. Cada tubería se modela como un camino posible, con capacidad y resistencia hidráulica.
- Feromonas digitales: En el ACO clásico, las feromonas representan rastros de éxito. En redes hídricas, se definen como variables dinámicas: presión mínima alcanzada, caudal promedio y frecuencia de suministro.
- Función objetivo: Minimizar inequidad de acceso y reducir pérdidas. El algoritmo ajusta horarios y caudales priorizando a nodos con mayor vulnerabilidad social.
- Parámetros de autoorganización: Siguiendo a Zhang (2013), los parámetros ρ (evaporación), ζ (oscilación) y c (coeficiente de acoplamiento) determinan estabilidad y convergencia. En agua intermitente, estos valores se calibran para equilibrar equidad y eficiencia.
- Estabilidad y resiliencia: El sistema es resiliente si alcanza un equilibrio estable bajo variaciones de oferta. Esto refleja adaptabilidad, condición central en sistemas hídricos urbanos.
- Implicaciones democráticas: Al ser auditable, el modelo permite que los usuarios comprendan las reglas de asignación. Esto favorece la legitimidad social del algoritmo, condición esencial para su aceptación política.

Política pública, resiliencia y democracia

La intermitencia no puede resolverse sin nuevos marcos de política pública. Proponemos tres pilares:

1. Tarifas inteligentes: progresivas, penalizando excesos y protegiendo a los hogares pobres.

2. Simuladores comunitarios: plataformas que permitan a los ciudadanos visualizar cómo sus hábitos afectan la red.
3. Gobernanza multinivel: articulación entre comunidades, operadores y reguladores.

El riesgo de captura tecnológica debe mitigarse mediante transparencia y control ciudadano. La IA no puede operar como caja negra: el agua es un derecho humano y su distribución debe ser abierta y verificable.

La inteligencia artificial no sólo puede diseñar esquemas más equitativos de distribución del agua, sino también impulsar una política pública orientada a la sostenibilidad. Mediante el análisis de patrones de consumo, la IA permite identificar a los hogares y comunidades que adoptan mejores prácticas ecológicas en el uso del recurso. Esto abre la puerta a un sistema de incentivos progresivos, es decir, descuentos en tarifas, mejoras en infraestructura doméstica y, a escala barrial, premios colectivos como una mayor continuidad en el servicio. De este modo, se fomenta un aprendizaje social donde la resiliencia hídrica se construye desde lo cotidiano.

Discusión

La propuesta, por tanto, abre debates en tres planos:

1. Técnico: la IA puede aumentar eficiencia y reducir pérdidas.
2. Social: existe riesgo de exclusión digital y desigualdad en acceso a información.
3. Político: la intermitencia puede transformarse en un espacio de participación democrática.

Comparaciones con otros sectores ilustran riesgos y oportunidades: en energía, los medidores inteligentes mejoraron eficiencia pero suscitaron críticas sobre privacidad. En salud, la IA apoyó el manejo de la pandemia, aunque reveló desigualdades. En transporte, los algoritmos optimizaron movilidad pero generaron nuevas formas de segregación espacial. Por lo tanto, la lección es clara: la tecnología nunca es neutra. Por ello, la intermitencia hídrica debe abordarse no solo como reto técnico, sino como oportunidad de innovación democrática.

Conclusiones

La intermitencia hídrica, lejos de ser un fracaso, puede convertirse en un motor de innovación social y tecnológica. El modelo propuesto, basado en ACO y teorías de autoorganización, muestra que es posible diseñar sistemas más justos y resilientes si se integran tres dimensiones: 1) Eficiencia técnica, al reducir pérdidas y optimizar caudales; 2) Justicia social, al priorizar a los hogares vulnerables; 3) Resiliencia democrática, al abrir la gestión al escrutinio ciudadano. Hacia el 2050, cuando el 66 % de la población vivirá en ciudades y el cambio climático reducirá la disponibilidad hídrica en regiones áridas hasta un 40 %, las soluciones convencionales serán insuficientes. El futuro requiere sistemas capaces de aprender colectivamente.

Por lo tanto, la intermitencia puede dejar de ser símbolo de precariedad y transformarse en un laboratorio de resiliencia democrática urbana, donde tecnología y ciudadanía converjan para garantizar el derecho humano al agua.

Bibliografía

Abhijith, G. R., Naidu, M. N., Boindala, S. P., Vasan, E., & Ostfeld, A. (2023). Journal of Hydroinformatics.

Bivins, A. W., Erickson, J. J., Hays, J., Money, E., & Nelson, K. L. (2017). Estimating the global burden of intermittent water supply. npj Clean Water.

Dorigo, M., & Stützle, T. (2004). Ant colony optimization. MIT Press.

Erickson, J. J., Nelson, K. L., & Meyer, D. J. (2022). Does intermittent supply result in hydraulic transients? AQUA.

Farmani, R., Charalambous, B., Nelson, K. L., & Dalton, J. (2023). Intermittent water supply: Challenges, opportunities and solutions. IWA Publishing.

Kumar, R., Singh, S., & Hossain, J. (2021). Applications of artificial intelligence in smart grids. Renewable and Sustainable Energy Reviews.

Nyenje, P. M., Wanyama, J., & Kansiime, F. (2021). Socio-institutional drivers of groundwater contamination hazards. Water.

Ostrom, E. (1990). Governing the Commons: The Evolution of Institutions for Collective Action. Cambridge University Press.

Satpathy, S., & Jha, R. (2022). Intermittent water supply in Indian cities. AQUA, 71(12), 1395–1407.

Vairavamoorthy, K., Gorantiwar, S. D., & Pathirana, A. (2007). Managing urban water supplies in developing countries. Water Policy.

Wu, W., Liu, J., & Yang, W. (2020). Applications of artificial intelligence in water systems. Environmental Science & Technology.

Yepes, G., Ringskog, K., & Sarkar, S. (2001). Problems faced by a national water utility in Tegucigalpa, Honduras. WIT Transactions on Ecology and the Environment.

Zhang, W. (2013). Self-organization: Theories and Methods. Sun Yat-sen University, Guangzhou, China.

DEL AHP AL RCCG: UNA EVOLUCIÓN METODOLÓGICA PARA EL ANÁLISIS DE LA INGOBERNABILIDAD DEL CICLO HIDROSOCIAL EN PUERTO MORELOS, QUINTANA ROO

SEBASTIÁN TORRES PERDIGÓN
Universidad Nacional Autónoma de México,
Facultad de Ciencias Políticas y Sociales ENES Mérida.

ARTÍCULO

Resumen

Este trabajo presenta el desarrollo del método RCCG (Rate of Change and Center of Gravity) como evolución metodológica del Proceso Analítico Jerárquico (AHP) para analizar la ingobernabilidad del ciclo hidrosocial. El método fue aplicado a 15 indicadores geoespaciales distribuidos en 4 dimensiones del ciclo hidrosocial, considerando los juicios de cinco expertos sobre 31 Unidades de Gestión Ambiental del municipio de Puerto Morelos. El RCCG generó umbrales dinámicos (umbral ponderado = 0.147) y un índice de compatibilidad entre expertos (G promedio = 0.5297), identificando 12 UGAs en situación crítica con consenso ≥60%. Esta metodología representa una mejora significativa al integrar tasas de cambio y análisis de compatibilidad, proporcionando umbrales adaptativos para facilitar la toma de decisiones en gestión hidrosocial.

Palabras clave: RCCG, AHP, ingobernabilidad, ciclo hidrosocial, análisis multicriterio

Introducción

La gestión de recursos hídricos en contextos metropolitanos requiere enfoques metodológicos especializados que interpreten los diversos conflictos emergentes bajo distintas escalas territoriales, sujetos a la complejidad de interacciones entre sistemas

naturales, sociales, institucionales y económicos (Swyngedouw, 2004; Linton & Budds, 2014).

Los métodos tradicionales de análisis multicriterio, particularmente el Proceso Analítico Jerárquico (AHP), han sido ampliamente utilizados para la evaluación de sostenibilidad hídrica (Saaty, 1980; Malczewski, 1999; Merino-Benítez & Bojórquez-Tapia, 2021) y recientemente para evaluar los niveles de ingobernabilidad de los territorios hidrosociales kársticos costeros de Puerto Morelos, Quintana Roo (Torres-Perdigón, 2024).

En esta investigación previa sobre los niveles de ingobernabilidad de los territorios hidrosociales kársticos costeros de Puerto Morelos se identificaron algunas limitaciones metodológicas: rigidez en umbrales fijos que no capturan la variabilidad temporal, espacial y subjetiva de los actores, y falta de análisis de sensibilidad dinámico que integre tasas de cambio entre criterios.

El concepto de "ingobernabilidad del ciclo hidrosocial" se define como la incapacidad sistémica del Estado, las instituciones y sociedad para gobernarse virtuosamente ante las interacciones complejas que se reproducen dentro del agua-territorio (Bakker, 2003; Castro, 2007).

Esta investigación desarrolla y valida el método RCCG como evolución metodológica del AHP multinivel para conocer los umbrales de ingobernabilidad del ciclo hidrosocial.

Desarrollo

Metodología

El estudio se realizó en el municipio de Puerto Morelos, Quintana Roo, abarcando 27 de 31 Unidades de Gestión Ambiental (UGAs) del Programa de Ordenamiento Ecológico Local (2013). Se conformó un panel de cinco expertos multidisciplinarios que asignaron pesos a 15 indicadores geoespaciales representativos de las dimensiones conceptuales de la ingobernabilidad del ciclo hidrosocial kárstico. Véase tabla 1 y gráfica 1.

El método RCCG introduce cinco innovaciones principales respecto al AHP tradicional (Garuti & Mu, 2024): cálculo de tasas de cambio entre indicadores adyacentes, umbrales locales dinámicos específicos para cada experto e indicador, perfiles

Código	Indicador	Dimensión	Tipo
3a1.1	COTERUR	Inestabilidad Institucional	Densidad
3a1.2	IDATM	Inestabilidad Institucional	Distancia
3a2.1	PIES1A5	Ineficiencia/Ineficacia	Área
3a2.2	PFP4FI	Ineficiencia/Ineficacia	Acumulación
3b1.1	PEH	Hidropolítica	Densidad
3b1.2	PDH	Hidropolítica	Densidad
3b2.1.1	VCE2013	Metabolismo Metropolitano	Volumen
3b2.1.2	DAADAU	Metabolismo Metropolitano	Distancia
3b2.2.1	AFFU	Metabolismo Metropolitano	Área
3b2.2.2	DCU	Metabolismo Metropolitano	Densidad
3b2.2.3	DPK	Metabolismo Metropolitano	Densidad
3b2.2.4	DPC	Metabolismo Metropolitano	Densidad
3b2.3.1	AAFIIU	Metabolismo Social	Área
3b2.3.2	IAHCSA	Metabolismo Social	Acumulación
3b3.1	NCH	Metabolismo Social	Número

Tabla 1: Estructura de Indicadores.

Gráfica 1: Pesos asignados

de umbral específicos para cada experto, índice de compatibilidad G entre perfiles de expertos, y umbral global ponderado basado en compatibilidad.

Las operaciones se automatizaron mediante script de R studio (ANEXO A) utilizando las librerías: dplyr, tidyverse, knitr, kableExtra, matrixcalc, igraph, ggplot2, gridExtra, ggstance.

Algoritmo RCCG

Paso 1: Re-Construcción de matrices de comparación pareada (realizados con los pesos normalizados en la investigación previa (Torres-Perdigón, 2024) con el software *SuperDecisions*

$$PCM_{ij} = \frac{W_i}{W_j}$$

Donde:
W_i = peso del indicador i
W_j = peso del indicador j

Paso 2: Verificación de consistencia (realizados con los pesos normalizados en la investigación previa (ibidem))

Donde:

$$\mathrm{CR} = \frac{CI}{RI}$$

$$\mathrm{CI} = \frac{\lambda max - n}{n-1}$$

λmax = valor propio máximo de la matriz de comparación
n = número de indicadores
RI = índice aleatorio de Saaaty correspondiente a n

Paso 3: Cálculo de tasas de cambio

$$Tasa_i = \frac{W_i^{superior}}{W_{i+1}^{inferior}}$$

Donde:
$W_i^{superior}$ = peso superior en el nivel jerárquico
$W_{i+1}^{inferior}$ = peso inferior asociado al siguiente nivel

Paso 4: Umbrales locales RCCG y correlaciones de Pearson entre expertos

$$U_i = \frac{2\, M_i\ L_i}{M_i + L_i}$$

Donde:
M_i = valor superior del indicador i, L_i = valor inferior del indicador i

$$rab = \frac{\Sigma_{i=1}^{n}\left(U_{i,a} - \underline{U}_a\right)\left(U_{i,b} - \underline{U}_b\right)}{\sqrt{\Sigma_{i=1}^{n}\left(U_{i,a} - \underline{U}_a\right)^2}\sqrt{\Sigma_{i=1}^{n}\left(U_{i,b} - \underline{U}_b\right)^2}}$$

Donde:
$\boldsymbol{U_{i,a}}$ = umbral local del indicador i según el experto a
$\boldsymbol{\underline{U}_a}$ = promedio de umbrales del experto a
n= 15 (indicadores analizados)

Paso 5: Umbral global ponderado

$$UG = \sum_{i=1}^{n} U_{i,} W_{i,}$$

Paso 6: Índice de compatibilidad G

$$G = \sum_{i=1}^{n} W_{i,} \frac{\min(P_{A,i}, P_{B,i})}{\max(P_{A,i}, P_{B,i})}$$

Donde:
$\boldsymbol{P_{A,i}}$ = valor del indicador i en el perfil A
$\boldsymbol{P_{B,i}}$ = valor del indicador i en el perfil B

Paso 7: Escalas adaptativas

Sea: el conjunto de expertos, donde:

- e1 = Sebastián, e2 = Arturo, e3 = Gaby, e4= Ayesa, e5= Patricia

Para cada experto , se define una función de escalas adaptativas:

10.2. Función de Escalas Adaptativas

Para cada experto ei y nivel $k \in \{1,2,\ldots,10\}$:

$$Nk_i e_i = (UGe_i)(F_k)$$

donde:

- $Nk_i e_i$ = umbral del nivel k para el experto e_i
- UGe_i = umbral global del experto e_i (calculado en Paso 6)
- F_k = factor de escala para el nivel k

10.3. Vector de Factores de Escala

$$F = (F1, F2, \ldots, F10)^T = (0.2, 0.4, 0.6, 0.8, 1.0, 1.2, 1.5, 2.0, 3.0, \infty)^T$$

Resultados

La distribución de pesos por dimensión (Véase Tabla 2) mostró diferentes enfoques entre expertos: Patricia y Ayesa priorizaron la Inestabilidad Institucional (49.5% y 41.7%), mientras que Sebastián enfatizó el Metabolismo Metropolitano Social y Ambiental (38.7%). El análisis de tasas de cambio reveló que Arturo presentó la mayor tasa entre sus indicadores principales (3.007), seguido de Patricia (2.079), y Gabriela mostró tasas de cambio sutiles y con el mayor indice G (0.6355). (Véase Gráfica 2 y Tlabla 3)

Dimensión	Sebastián	Arturo	Gaby	Ayesa	Patricia	Promedio
Inestabilidad Institucional	0.093	**0.24**	0.175	**0.417**	**0.495**	**0.284**
Ineficiencia/Ineficacia	0.036	0.060	**0.025**	0.083	0.055	0.0518
Metabolismo Metropolitano-social	**0.387**	0.090	**0.261**	0.063	0.034	0.167
Metabolismo Metropolitano-ambiental	**0.387**	0.016	0.083	0.008	0.020	0.1028
Metabolismo Metropolitano-Estatal	0.033	0.067	0.155	0.028	0.010	0.0586
Metabolismo Social	0.032	**0.433**	**0.177**	**0.321**	0.163	**0.225**
Hidropolítica	0.032	0.094	0.124	0.080	**0.223**	0.1106

Tabla 2. Distribucion de pesos por dimensión (%)

Gráfica 2: Umbrales locales de los expertos.

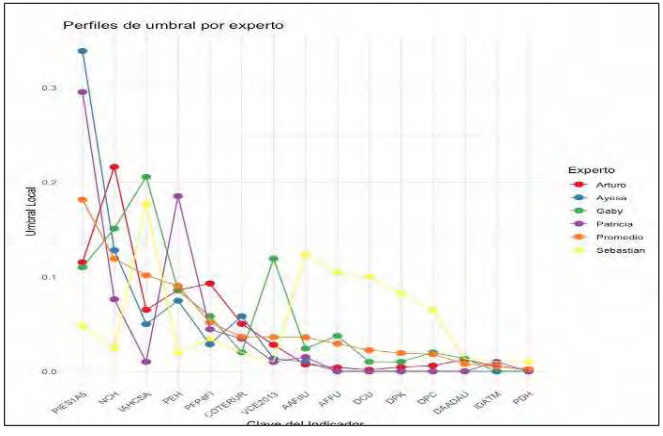

Orden jerárquico	Sebastián	Arturo	Gaby	Ayesa	Patricia
1	IAHCSA → AAFIIU (1.688)	NCH → PIES1A5 (3.007)	IAHCSA → NCH (1.328)	PIES1A5 → NCH (1.137)	PIES1A5 → PEH (2.079)
2	AAFIIU→ AFFU (1.297)	PIES1A5 → PFP4FI (1.500)	NCH → VCE2013 (1.341)	NCH → PEH (4.169)	PEH → NCH (1.313)
3	AFFU → DCU (1.067)	PFP4FI → PEH (1.067)	VCE2013 → PEH (1.179)	PEH → COTERUR (1.055)	NCH → PFP4FI (3.260)
4	DCU → DPK (1.040)	PEH → IAHCSA (1.098)	PEH → PIES1A5 (1.067)	PFP4FI → IAHCSA (1.404)	PFP4FI → COTERUR (1.136)
5	DPK → DPC (1.389)	IAHCSA → COTERUR (1.519)	PIES1A5 → PFP4FI (1.5)	IAHCSA → VCE2013 (1.040)	COTERUR → AAFIIU (1.630)

Tabla 3: Tasas de cambio de los expertos.

Los umbrales globales calculados fueron: Sebastián (0.1038), Arturo (0.1366), Gaby (0.1192), Ayesa (0.1797) y Patricia (0.1866), con un promedio de 0.1449 y umbral ponderado de 0.147. El índice G promedio fue de 0.5297, indicando baja compatibilidad general, pero con correlaciones significativas entre pares específicos de expertos. (Véase Gráfica 3)

Se identificaron 12 UGAs en situación crítica con consenso ≥60%, simebrago las 5 UGAs mas ingobernables son: UGA 30 (Zona urbana Puerto Morelos, 0.5966), UGA 03 (Forestal de Leona Vicario, 0.4826), UGA 11 (Ejidos de Puerto Morelos, 0.3776), UGA 06-c

Gráfica 3: Correlación de Pearson entre umbrales locales

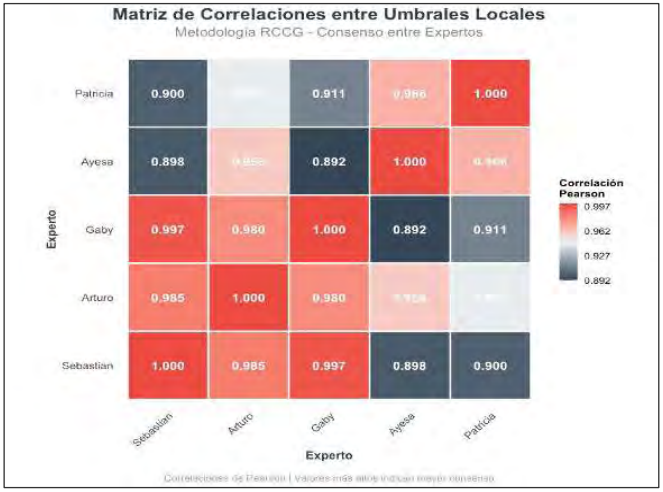

(Protección de Pozos, 0.2927) y UGA 08 (Corredor Cancún-Leona Vicario, 0.2366).(Véase Tabla 4 y Gráfica 4)

Comparación AHP vs RCCG

El método RCCG presentó ventajas significativas: umbrales dinámicos específicos por experto versus umbrales fijos del AHP; índice G grupal versus CR individual; ponderación por compatibilidad versus

Experto	Umbral Global	Índice G	Compatibilidad
Sebastián	0.1038	0.3328	baja
Arturo	0.1366	0.598	baja
Gaby	0.1192	0.6355	media
Ayesa	0.1797	0.5903	baja
Patricia	0.1866	0.4897	baja
Promedio	**0.1449**	**0.5297**	baja
Ponderado	**0.147**	-	-

Tabla 4: Umbrales globales e Indice G

ponderación igual; mayor sensibilidad mediante tasas de cambio; e identificación de 19 UGAs críticas (73.33%) versus 13 del AHP tradicional (50%).

Las escalas adaptativas permitieron interpretaciones diferenciadas según cada experto, con umbrales específicos que reflejan la percepción individual de cada miembro del panel. (Véase Tabla 5)

Ventajas del Método RCCG

Los umbrales adaptativos del RCCG generan valores críticos basados en la percepción transitiva de los

Gráfica 4 Umbrales Globales por UGA

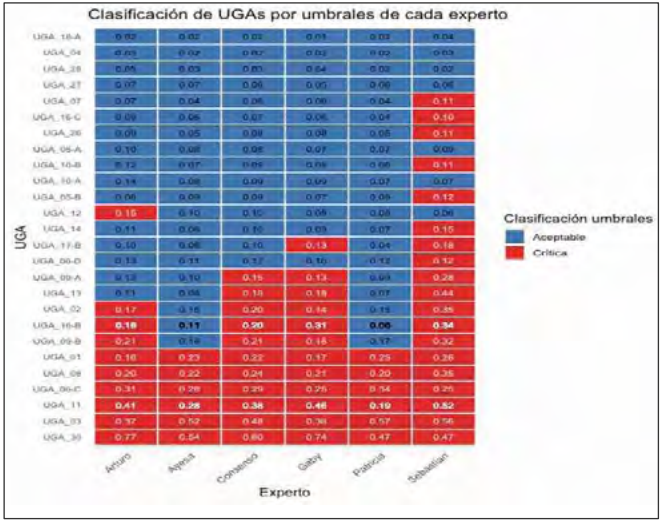

expertos, no valores estáticos. El umbral ponderado (0.147) incorpora tanto la distribución de pesos como la confiabilidad de cada miembro del panel. A pesar de la baja compatibilidad general, las correlaciones de Pearson revelan posibilidades de consensos subconscientes entre actores bajo ciertas dimensiones específicas.

Tabla 5: Comparación metodológica

Criterio	AHP Tradicional	RCCG
Umbral	Fijo (aumentando en rangos o niveles de 0.05 hasta llegar a 0.20)	Dinámico, depende de la percepción del experto o del consenso del panel, ya sea: 0.1038, 0.1366, 0.1192, 0.1797, 0.1866, 0.1449 o 0.147.
Compatibilidad	CR individual	Índice G grupal
Ponderación	Igual para todos	Por compatibilidad
Sensibilidad	Limitada	Tasas de cambio entre indicadores adyacentes
UGAs críticas para el investigador	13 (50% de las UGAs)	19 (73.33% de las UGAs)

Los patrones espaciales identificados muestran concentración de ingobernabilidad en zonas urbanas, corredores turísticos y zonas ejidales con recursos geohidrologicos geoestratégicos, información valiosa para la priorización de intervenciones y el monitoreo adaptativo. (Véase tabla 6)

Tabla 6: Comparación de escalas entre Sebastián y Gabriela

Escalas de Sebastián.				Escalas de Gabriela			
Nivel	Mín	Máx	Interpretación	Nivel	Mín	Máx	Interpretación
1	0	0.0208	Gobernabilidad estable	1	0	0.0238	Gobernabilidad estable
2	0.0208	0.0415	Tensiones menores	2	0.0238	0.0477	Tensiones menores
3	0.0415	0.0623	Desajustes localizados	3	0.0477	0.0715	Desajustes localizados
4	0.0623	0.083	Presión moderada	4	0.0715	0.0954	Presión moderada
5	0.083	0.1038	Umbral crítico alcanzado	5	0.0954	0.1192	Umbral crítico alcanzado
6	0.1038	0.1245	Ingobernabilidad emergente	6	0.1192	0.1431	Ingobernabilidad emergente
7	0.1245	0.1557	Ingobernabilidad manifiesta	7	0.1431	0.1788	Ingobernabilidad manifiesta
8	0.1557	0.2076	Crisis de gobernanza severa	8	0.1788	0.2384	Crisis de gobernanza severa
9	0.2076	0.3113	Crisis sistémica avanzada	9	0.2384	0.3577	Crisis sistémica avanzada
10	0.3113	1	Colapso total del sistema	10	0.3577	1	Colapso total del sistema

Conclusiones

El método RCCG representa una evolución significativa del AHP tradicional para el análisis democrático de sistemas complejos. Los umbrales dinámicos mejoran la precisión y adaptabilidad de las decisiones en alianzas, mientras que el índice de compatibilidad G proporciona medidas más robustas para tomar decisiones en consenso.

Se identificaron 12 UGAs críticas en consenso con diferentes niveles de ingobernabilidad, mostrando patrones espaciales de concentración en zonas urbanas, corredores turísticos y zonas ejida-

les. Estos resultados proporcionan herramientas para la priorización de intervenciones, monitoreo adaptativo y desarrollo de políticas diferenciadas según el tipo de ingobernabilidad percibida.

Las limitaciones incluyen la dependencia de juicios expertos y mayor complejidad computacional. Se recomienda implementar monitoreo continuo de UGAs críticas, desarrollar estrategias diferenciadas y fortalecer capacidades institucionales multinivel.

El RCCG facilita la identificación de consensos científicos y alianzas de preferencias, mejorando la toma de decisiones participativa en la gestión de territorios hidrosociales complejos.

Bibliografía

Bakker, K. (2003). An uncooperative commodity: Privatizing water in England and Wales. Oxford University Press.

Castro, J. E. (2007). Water governance in the twentieth-first century. Environment and Urbanization, 19(2), 441-462.

Garuti, C., & Mu, E. (2024). A Rate of Change and Center of Gravity Approach to Calculating Composite Indicator Thresholds: Moving from an Empirical to a Theoretical Perspective. Mathematics, 12(13). https://doi.org/10.3390/math12132019

Linton, J., & Budds, J. (2014). The hydrosocial cycle: Defining and mobilizing a relational-dialectical approach to water. Geoforum, 57, 170-180.

Malczewski, J. (1999). GIS and multicriteria decision analysis. John Wiley & Sons.

Merino-Benítez, T., & Bojórquez-Tapia, L. (2021). Modelación y Simulación Dinámica de Sistemas Socioambientales. http://www.apc.lancis.ecologia.unam.mx/modulos/ordenamiento/docs/build/html/pronostico.html

Modificación del Programa de Ordenamiento Ecológico Local del Municipio de Benito Juárez, Quintana Roo, (2013).

Saaty, T. L. (1980). The analytic hierarchy process. McGraw-Hill.

Saaty, R. W. (1987). The analytic hierarchy process-what it is and how it is used. Mathematical Modelling, 9(3–5), 161–176. https://doi.org/10.1016/0270-0255(87)90473-8

Swyngedouw, E. (2004). Social power and the urbanization of water. Oxford University Press.

Torres-Perdigón, S. (2022). La configuración conflictiva del ciclo hidrosocial del norte de Quintana Eoo 2012-2021. apuntes para la seguridad de los recursos hídricos. tesis de especialidad en negociación y gestión de conflictos políticos y sociales. in Universidad Nacional Autónoma de México. facultad de ciencias políticas.

Torres-Perdigón, S. (2024). Propuesta teórico-metodológica para analizar los niveles de ingobernabilidad de los territorios hidrosociales en Puerto Morelos. tesis en gobierno y asuntos públicos. in UNAM.

LA INTELIGENCIA ARTIFICIAL Y SU APLICACIÓN EN EL DESARROLLO DE NUEVOS MATERIALES PARA ATENDER RETOS NACIONALES EN EL ÁREA DE LA CALIDAD Y SANEAMIENTO DEL AGUA

ADRIÁN BONILLA-PETRICIOLET,
DIDILIA ILEANA MENDOZA-CASTILLO,
HILDA ELIZABETH REYNEL-ÁVILA,
MA. DEL ROSARIO MORENO-VIRGEN
Tecnológico Nacional de México – Instituto Tecnológico de Aguascalientes

ARTÍCULO

Resumen

En este artículo se contextualiza la problemática de calidad del agua y su purificación en México, y se discute la aplicación de la Inteligencia Artificial para contribuir a su resolución a través del desarrollo de nuevos adsorbentes para la remoción de contaminantes prioritarios.

Introducción: Los retos de la calidad del agua y su saneamiento en México

La calidad del agua y su saneamiento son dos retos prioritarios que enfrenta la sociedad mexicana. Diversos estudios han documentado que las actividades antropogénicas y factores naturales (por ejemplo, la composición geológica de los acuíferos) contribuyen a la contaminación de las fuentes de abastecimiento de agua para uso y consumo humano en México (Acuña-Bedoya et al., 2025). La presencia de contaminantes orgánicos e inorgánicos, que impactan el medio ambiente y generan riesgos para la salud pública, ha sido confirmada en diferentes acuíferos del país. Por ejemplo, se ha determinado que algunos de los pozos que se utilizan para abastecimiento de agua en los estados de Aguascalientes, Estado de México, Jalisco y San Luís Potosí presen-

tan contenidos de fluoruros superiores a los valores establecidos por la normatividad nacional (Alarcón-Herrera et al., 2020). La exposición crónica a dicho contaminante geogénico, a través del consumo de agua, está vinculada con la incidencia de fluorosis dental entre la población expuesta y es un factor de riesgo asociado a otras afecciones como las enfermedades renales (Villalvazo et al., 2021). Los resultados de otros diagnósticos permiten concluir que escenarios similares ocurren para contaminantes aún más tóxicos, como es el caso del arsénico que es carcinogénico, y cuyas concentraciones en los acuíferos de algunas regiones de México son muy superiores al límite de concentración establecido para proteger la salud pública (Alarcón-Herrera et al., 2020).

Actualmente, se cuenta con diferentes tecnologías comerciales que pueden utilizarse para la purificación del agua. No obstante, la principal restricción para su implementación en México, y en particular en zonas vulnerables con limitaciones económicas, es su costo, el cual se incrementa para el tratamiento de agua que contiene contaminantes difíciles de remover como fluoruros, arsénico, mercurio, entre otros (Aguilar-Aguilar et al., 2023). La reducción de los costos del saneamiento del agua para cumplir con los parámetros de calidad establecidos en la normatividad nacional es un factor clave para asegurar el cumplimiento del objetivo No. 6 de la Agenda 2030 para el Desarrollo Sostenible, es decir, “garantizar la disponibilidad de agua y su gestión sostenible y el saneamiento para todos” (Organización de la Naciones Unidas, 2025). La resolución de esta problemática requiere el desarrollo de nuevos materiales y tecnologías que ofrezcan el mejor desempeño posible para la remoción de un amplio espectro de contaminantes, pero cuyo valor comercial sea accesible para que se pueda garantizar su aplicación con el presupuesto público disponible, mejorando la calidad de vida de la población, pero sin ocasionar incrementos de tarifas de los servicios o cargas tributarias adicionales.

La Inteligencia Artificial es una de las herramientas que puede contribuir a impulsar la agenda científica y tecnológica para la producción de nuevos materiales que permitan la purificación efectiva y económica del agua (Ji et al., 2025). Esta

herramienta ha sido muy útil para minimizar costos y mejorar la operación de diferentes procesos y servicios. En el área de tratamiento de agua, se puede utilizar para reducir los precios de fabricación de nuevos materiales, encontrar materiales con propiedades mejoradas y optimizar las condiciones de operación que favorezcan su desempeño (Ray et al., 2023; Bhatt et al., 2025). En esta contribución, se discute brevemente la aplicación de la Inteligencia Artificial y sus potenciales beneficios para la preparación de nuevos materiales utilizados en procesos de adsorción para remover contaminantes prioritarios del agua, así como la optimización de sus propiedades y condiciones de síntesis.

Inteligencia Artificial y su aplicación en el desarrollo de nuevos adsorbentes para el tratamiento de agua

La adsorción es uno de los procesos más efectivos y rentables, en comparación con otras tecnologías disponibles en el mercado, para el saneamiento de agua contaminada por especies orgánicas e inorgánicas. En este proceso de tratamiento se utiliza un material sólido (denominado como adsorbente), el cual tiene una estructura usualmente porosa cuya composición y características de superficie permiten interactuar de manera selectiva con las sustancias de interés (adsorbatos, los cuales son los contaminantes) que están disueltas en el fluido a purificar (Bonilla-Petriciolet et al., 2019). La efectividad y el costo del proceso de adsorción depende de las características del adsorbente, las cuales a su vez están definidas por las materias primas, las tecnologías y condiciones para realizar la preparación y procesos de activación del sólido que servirá como material filtrante para la purificación del agua. Dependiendo del tipo de contaminante a ser removido, las condiciones de producción del adsorbente, y en consecuencias sus características fisicoquímicas, deben ser modificadas para optimizar su desempeño.

La inteligencia artificial se puede utilizar para establecer las condiciones de síntesis que generen las mejores características finales (porosidad, química de superficie, capacidad de regeneración y reutilización) de un adsorbente para lograr una remoción efectiva de un contaminante en particu-

lar. En la Figura 1 se muestra este enfoque para la producción de nuevos materiales destinados a la remoción de contaminantes del agua. Con fines ilustrativos, se asumirá que se está interesado en preparar un carbón activado, empleando los residuos de la cáscara de coco (como materia prima) y procesos de pirólisis y activación química o física. El objetivo es obtener un material cuyas propiedades sean las mejores para remover diferentes contaminantes del agua. Primero, es necesario integrar una base de datos con la mayor cantidad de información disponible (estudios reportados en la literatura y cuantificaciones experimentales propias) para este tipo de adsorbente. Esta base de datos podría incluir la siguiente información:

Figura 1. Ilustración de la aplicación de Inteligencia Artificial para preparar nuevos adsorbentes para la remoción de contaminantes del agua.

a. las condiciones de pirólisis y de los procesos de activación química y física aplicados para la obtención del carbón activado.
b. las principales propiedades (por ejemplo, área de superficie, grupos funcionales, estructuras cristalinas) del carbón activado obtenido a las diferentes condiciones de síntesis.
c. las características de los contaminantes, las cuales pueden estar asociadas a propiedades de sus estructuras químicas o moleculares que permitan su diferenciación y clasificación.
d. el desempeño del carbón activado para los diferentes contaminantes estudiados donde se debe recolectar información de

isotermas, cinéticas y curvas de ruptura de adsorción y otros parámetros termodinámicos del proceso de tratamiento incluyendo las condiciones de remoción y las características principales del fluido tratado (por ejemplo, pH, temperatura, salinidad).

La herramienta de Inteligencia Artificial, la cual podría ser una red neuronal artificial u otro algoritmo de aprendizaje de máquina (Yu et al., 2025), se utilizará para "aprender" cómo impactan las características del proceso de preparación del carbón activado en sus propiedades de superficie y, principalmente, en su desempeño de remoción de diferentes contaminantes. La red neuronal establecerá la funcionalidad existente entre el conjunto de variables de entrada y la variable de interés (en este caso, la remoción de contaminantes). El modelo que se obtenga de esta fase tendrá la capacidad de "predecir" el desempeño de remoción de los contaminantes estudiados de un carbón activado que se prepare a condiciones previamente definidas. Dicho modelo basado en Inteligencia Artificial permitiría analizar y determinar qué condiciones de producción podrían ser las más favorables para obtener un adsorbente con la mejor capacidad de remoción para un contaminante en particular, o con un comportamiento promedio para varios contaminantes. Los resultados del modelo se utilizarían para realizar la preparación del material y su aplicación en los estudios de remoción de contaminantes.

Este enfoque ayudaría a reducir de forma significativa el costo (es decir, reactivos, uso de instalaciones y equipos, salarios) y el tiempo para la síntesis de del carbón activado. Es conveniente indicar que este tipo de modelos basados en Inteligencia Artificial tienen un mayor potencial para el diseño de materiales estructurados, desde el punto de vista molecular, como son los armazones organometálicos (mejor conocidos como MOFs por sus siglas en inglés) y otros adsorbentes que tengan estructuras regulares y ordenadas, y que usualmente son compuestos cristalinos cuyas propiedades son relativamente más fáciles de simular (Zhang et al., 2025). Para el caso de adsorbentes con estructuras amorfas (como los materiales a base de carbono), es posible que la herramienta de Inteli-

gencia Artificial presente un mayor grado de incertidumbre (debido a la naturaleza heterogénea del material) pero su utilización ayudaría significativamente a la optimización de los recursos utilizados en su producción. Por otra parte, el enfoque de Inteligencia Artificial descrito en la Figura 1 se puede acoplar a herramientas de química computacional (las cuales son útiles para predecir teóricamente las propiedades de sistemas en función de su estructura molecular) para obtener mejores resultados e incrementar el grado de entendimiento y racionalización del sistema.

Otros usos potenciales de la Inteligencia Artificial en el área de adsorción implican la predicción del desempeño de equipos de tratamiento para determinar los tiempos de reemplazo del adsorbente saturado para su reactivación y la predicción del desempeño del adsorbente cuando otros contaminantes o sustancias se encuentran presentes en el fluido a purificar (Azhar et al., 2023; Coutinho et al., 2025).

Conclusiones

El desarrollo de nuevos materiales para resolver los problemas de calidad y saneamiento del agua en México se puede impulsar mediante la aplicación de Inteligencia Artificial. En particular, esta herramienta puede utilizarse para producir mejores adsorbentes que sean útiles para reducir los costos de tratamiento y purificación de agua en zonas vulnerables en México donde los acuíferos están contaminados por compuestos tóxicos al organismo humano y que están generando problemas de salud pública.

Referencias

Acuña-Bedoya, J.D., Borja-Maldonado, F., Herrera-Domínguez, M., López-Zavala, M.A. (2025). Current situation of emerging contaminants in Mexican waters and treatment perspectives. Current Opinion in Environmental Science Health, 46, 100636. https://doi.org/10.1016/j.coesh.2025.100636

Aguilar-Aguilar, A., Díaz de León-Martínez, L., Forgionny, A., Acelas Soto, N.Y., Rosales Mendoza, S., Zárate-Guzmán, A.I. (2023). A systematic review on the current situation of emerging pollutants in Mexico: a perspective on policies, regulation, detection, and elimination in water and wastewater. Science of the Total Environment, 905, 167426. https://doi.org/10.1016/j.scitotenv.2023.167426

Alarcón-Herrera, M.T., Martin-Alarcon, D.A., Gutiérrez, M., Reynoso-Cuevas, L., Martín-Domínguez, A., Olmos-Márquez, M.A., Bundschuh, J. (2020). Co-ocurrence, possible origin, and health risk assessment of arsenic and fluoride in drinking water sources in Mexico: geographical data visualization. Science of the Total Environment 698, 134168. https://doi.org/10.1016/j.scitotenv.2019.134168

Azhar, B., Avian, C., Tiwikrama, A.H. (2023). Green synthesis optimization with artificial intelligence studies of copper-gallic acid metal-organic frameworks and its application in dye removal from wastewater. Journal of Molecular Liquids, 389, 122844. https://doi.org/10.1016/j.molliq.2023.122844

Bhatt, D., Swain, M., Yadav, D. (2025). Artificial intelligence based detection and control strategies for river water pollution: a comprehensive review. Journal of Contaminant Hydrology, 271, 104541. https://doi.org/10.1016/j.jconhyd.2025.104541

Bonilla-Petriciolet, A., Mendoza-Castillo, D.I., Dotto, G.L., Duran-Valle, C.J. (2019). Adsorption in water treatment. Reference Module in Chemistry, Molecular Sciences and Chemical Engineering. https://doi.org/10.1016/B978-0-12-409547-2.14390-2

Coutinho, R., Hoshima, H.Y., Marques, M. (2025). Enhanced removal of low-concentrations of PFOA from water and wastewater with a novel luffa sponge-derived adsorbent: one-step synthesis and optimization using design of experiments and artificial neural network. Biomass Bioenergy, 202, 108208. https://doi.org/10.1016/j.biombioe.2025.108208

Ji, Y., Sun, W., Shah, K.J., Sun, Y. (2025). A review on application of artificial intelligence in the construction of environmental functional materials. Desalination Water Treatment, 323, 101384. https://doi.org/10.1016/j.dwt.2025.101384

Organización de las Naciones Unidas (2025). Objetivos de Desarrollo Sostenible. https://www.un.org/sustainabledevelopment/es/

Ray, S.S., Verma, R.K., Singh, A., Ganesapillai, M., Kwon, Y.N. (2023). A holistic review on how artificial intelligence has redefined water treatment and seawater desalination processes. Desalination, 546, 116221. https://doi.org/10.1016/j.desal.2022.116221

Villalvazo, P., Carriazo, S., Martin-Cleary, C., Ortiz, A. (2021). Aguascalientes: one of the hottest chronic kidney disease (CKD) hotspots in Mexico and a CKD of unknown aetiology mystery to be solved. Clinical Kidney Journal, 14, 11, 2285-2294. https://doi.org/10.1093/ckj/sfab136

Yu, W., Zhou, Z., Yang, Y., Li, X., Lu, Z., Liu, Y., Ren, J., Liu, Y. (2025). Artificial intelligence in chemical dosing for drinking water treatment: a systematic review of algorithmic applications, implementation frameworks, and future challenges. Journal of Environmental Chemical Engineering, 13, 5, 118936. https://doi.org/10.1016/j.jece.2025.118936

Zhang, L., Wang, Y., Chen, Y., Wu, Z., Tan, J., Li, J., Chen, B., Li, L. (2025). Metal-organic frameworks for ethane-selective adsorption: a comprehensive review on structural design and separation applications. Coordination Chemistry Reviews, 544, 216974. https://doi.org/10.1016/j.ccr.2025.216974

TRATAMIENTOS BASADOS EN APRENDIZAJE AUTOMÁTICO PARA LA REUTILIZACIÓN DEL AGUA EN APLICACIONES INDUSTRIALES Y URBANAS

JORGE ALEJANDRO SILVA RODRÍGUEZ DE SAN MIGUEL
Instituto Politécnico Nacional

ARTÍCULO

Resumen

El reciclaje de agua para las ciudades y la industria todavía se enfrenta a enemigos implacables: calidad variable del afluente, procesos de tratamiento que consumen mucha energía, membranas sucias y falta de detección en tiempo real. Sin embargo, con los recientes avances en inteligencia artificial (IA) y aprendizaje automático (ML), estos desafíos se pueden aliviar con sensores blandos para parámetros difíciles de medir. Este artículo resume estudios recientes y la experiencia de implementación, contextualizándolos en relación con las estructuras regulatorias y de gobernanza actualizadas. Se presenta una implementación con una hoja de ruta. ML, si se integra con aplicaciones de ingeniería, validación y gestión de riesgos de IA, puede permitir la estabilización en la calidad de los efluentes, con reducciones de costos y una seguridad acelerada en la reutilización industrial y urbana bajo una guía moderna.

Introducción

El aumento de las presiones climáticas, la urbanización y la demanda industrial ejercen una mayor

presión sobre los sistemas de agua dulce. La reutilización apta para el uso (agua de alta pureza en refrigeración/riego y, donde está permitido, reutilización directa e indirecta de agua potable) se ha desarrollado técnicamente, pero es operativamente delicada debido a la diversidad de afluentes, los costos energéticos/químicos, la contaminación y las mediciones en línea esporádicas de indicadores clave (p. ej., demanda bioquímica de oxígeno a 5 días [DBO5], riesgo microbiano) (Alvi et al., 2023). La literatura reciente también reporta beneficios significativos del ML en el ciclo de aguas residuales y aguas urbanas, en particular el aprendizaje profundo para la detección suave, la previsión y el control (Alvi et al., 2023). Las implementaciones también deben ser relevantes para los marcos actuales: las Guías de la Organización Mundial de la Salud (OMS) para la Calidad del Agua Potable de 2022, el reglamento de la UE sobre reutilización del agua y el progreso del Plan de Acción para la Reutilización del Agua (WRAP) de la Agencia de Protección Ambiental (EPA) de Estados Unidos de América (EE. UU.) (European Commission, 2023; WHO, 2022).

Aprendizaje automático para la reutilización del agua

El ML está revolucionando la reutilización del agua al combinar datos a diferentes escalas: señales capturadas en tiempo real en SCADA (caudal, presión, absorbancia del agua a una longitud de onda de 254 nanómetros de luz ultravioleta (UV254), turbidez, potencial de hidrógeno [pH], potencial de oxidación-reducción, conductividad), análisis de laboratorio (demanda bioquímica de oxígeno [DBO], demanda química de oxígeno [DQO], Escherichia coli [E. coli]), registros de energía, telemetría, así como variables exógenas como la meteorología y la producción (Alvi et al., 2023; Duarte et al., 2023). Aprovechar esta heterogeneidad implica metodologías de integración avanzadas, como la sincronización de la base temporal, la detección automatizada de la deriva del sensor, la introducción del aprendizaje activo para regímenes inciertos y la partición de regímenes operativos (Alvi et al., 2023; Duarte et al., 2023).

Un avance importante es el uso de sensores blandos para predecir condiciones costosas o que requieren mucho tiempo utilizando una pequeña

cantidad de datos UV-Vis (espectroscopía ultravioleta-visible) o de fluorescencia. Investigaciones más recientes han demostrado que la DQO, los SST (sólidos suspendidos totales) y la E. coli pueden predecirse con un alto grado de precisión de forma continua, necesaria para usos prácticos como la dosificación temprana de coagulantes, la optimización de la POA (procesos de oxidación avanzada), el control de la nitrificación y la planificación de la desinfección (Shyu et al., 2023, Cardia et al., 2023, Lechevallier et al., 2025).

Las técnicas de detección de anomalías (bosque de aislamiento, PCA [análisis de componentes principales] robusto, autocodificadores) pueden ser útiles para detectar incidentes tóxicos repentinos, como emisiones de contaminación de la industria o fallos operativos, y para mejorar los sistemas de gestión basados en riesgos, siguiendo las recomendaciones de la OMS (WHO, 2022). De igual manera, el ML complementa la gestión del ensuciamiento de las membranas gracias a su capacidad para predecir la presión transmembrana, optimizar las limpiezas y evaluar su eficiencia con enfoques híbridos que integran la física y los datos para mejorar la transferibilidad (Abuwatfa et al., 2023; Ignacz et al., 2025).

Otro aspecto importante es la minimización del consumo de energía y productos químicos, mediante el uso de enfoques de control predictivo para modificar la dosificación y la aireación y alcanzar los límites de regulación a un costo mínimo (Hermes et al., 2025; Frederick et al., 2024). A nivel de sistema, se ha avanzado en la predicción del cloro residual y en la gestión de las operaciones de las estaciones de bombeo para reducir el riesgo de sobrealimentación (Hermes et al., 2025; Frederick et al., 2024). Además, gracias a los gemelos digitales, es posible simular fenómenos hidráulicos y de dinámica de calidad en redes urbanas de agua no potable, como el control de la demanda, las fugas y la desinfección residual (Ramos et al., 2024; Cejudo et al., 2023). En el caso de los sistemas de refrigeración, el ML facilita la optimización de los ciclos de concentración, corrosión y costes de reposición de agua en las torres de refrigeración (Ramos et al., 2024; Cejudo et al., 2023).

El uso del aprendizaje automático en el sector deberá adherirse a la gobernanza y la ética (en esencia, la calidad del agua [OMS, Reglamento UE 2020/741] y la normativa de IA [NIST AI RMF 1.0 [2023] y la Ley de IA de la UE [2024]). Esto exige transparencia, trazabilidad y supervisión humana que garantice la seguridad operativa (European Commission, 2023; NIST, 2023).

Para la implementación y la hoja de ruta por etapas, el sistema resultante combina flujo SCADA, almacenamiento de series temporales y funciones de ingeniería, registro e implementación gradual de modelos con protección perimetral.

Etapa 1 (pilotos): Sensores flexibles (DQO/DBO/SST), detección de anomalías sin supervisión y análisis de viabilidad (reducción de incumplimientos, costos de laboratorio, así como de productos químicos y energía).

Etapa 2 (mayor control): Predicciones para la optimización y el equilibrio entre dosificación, aireación y membranas, con rangos de incertidumbre; detecciones y reversiones de derivas.

Fase 3 (integración en la red): Predicción de demanda y residuos, programación de conductores, conectividad de gemelos digitales y paneles de indicadores clave de rendimiento (KPI) (energía, productos químicos, limpieza, cumplimiento).

Conclusiones

En la actualidad, el ML tiene el potencial de mejorar drásticamente la sostenibilidad y reducir el coste de la reutilización industrial y urbana al permitir la detección suave de parámetros críticos, la detección temprana de anomalías, el control predictivo de las incrustaciones y la optimización multiobjetivo de la energía y las sustancias químicas. Su adopción debe estar en consonancia con los marcos regulatorios vigentes (WHO, 2022) y la gobernanza actualizada de riesgos de IA (NIST AI RMF; Ley de IA de la UE), que abarca una validación exhaustiva, la generación de informes de incertidumbre e interfaces de usuario centradas en el operador. Una hoja de ruta por etapas, que comienza con la preparación de datos y los pilotos de no arrepentimiento,

desarrolla la capacidad a medida que protege la salud pública y la integridad de los activos.

Referencias

Abuwatfa, W. H., AlSawaftah, N., Darwish, N., Pitt, W. G., & Husseini, G. A. (2023). A Review on Membrane Fouling Prediction Using Artificial Neural Networks (ANNs). Membranes, 13(7), 685. https://doi.org/10.3390/membranes13070685

Alvi, M., Batstone, D., Mbamba, C. K., Keymer, P., French, T., Ward, A., Dwyer, J., & Cardell-Oliver, R. (2023). Deep learning in wastewater treatment: a critical review. Water Research, 245, 120518. https://doi.org/10.1016/j.watres.2023.120518

Cardia, M., Stefano Chessa, Franceschi, M., Gambineri, F., & Micheli, A. (2023). Machine Learning for the Estimation of COD from UV-Vis Spectrometer in Leather Industries Wastewater. International Journal of Environmental Pollution and Remediation , 11, 10–19. https://ijepr.avestia.com/2023/002.html?utm_source=

Cejudo, C. E., Pamintuan, B. C., Stoughton, K., & Whitfield, M. (2023). Emerging Technologies Review: Water Reuse Systems for Cooling Tower Applications (pp. 1–37) [Review of Emerging Technologies Review: Water Reuse Systems for Cooling Tower Applications]. Pacific Northwest National Laboratory. https://

www.pnnl.gov/main/publications/external/technical_reports/PNNL-34788.pdf?utm_source=

Duarte, M. S., Martins, G., Oliveira, P., Fernandes, B., Ferreira, E. C., Alves, M. M., Lopes, F., Pereira, M. A., & Novais, P. (2023). A review of computational modeling in wastewater treatment processes. ACS ES&T Water, 4(3), 784–804. https://doi.org/10.1021/acsestwater.3c00117

European Commission. (2023). Water reuse. https://environment.ec.europa.eu/topics/water/water-reuse_en?utm_source=

Frederick, F. D., Marlim, M. S., & Kang, D. (2024). Optimization of Chlorine Injection Schedule in Water Distribution Networks Using Water Age and Breadth-First Search Algorithm. Water, 16(3), 486. https://doi.org/10.3390/w16030486

Hermes, L., André Artelt, Vrachimis, S. G., Polycarpou, M. M., & Hammer, B. (2025). A Benchmark for Physics-informed Machine Learning of Chlorine Concentration States in Water Distribution Networks. SN Computer Science, 6(5). https://doi.org/10.1007/s42979-025-04008-y

Ignacz, G., Bader, L., Beke, A. K., Ghunaim, Y., Shastry, T., Vovusha, H., Carbone, M. R., Ghanem, B., & Szekely, G. (2024). Machine learning for the advancement of membrane science and technology: A critical review. Journal of Membrane Science, 713, 123256. https://doi.org/10.1016/j.memsci.2024.123256

Lechevallier, P., Gruber, G., Vojtěch Bareš, Neuenhofer, N., Waldner, L., Mahajan, A., Mutzner, L., & Rieckermann, J. (2025). Dataset on wastewater quality monitoring with adsorption and reflectance spectrometry in the UV-vis range. Scientific Data, 12(1). https://doi.org/10.1038/s41597-025-05459-x

NIST. (2023). AI Risk Management Framework. Artificial Intelligence Risk Management Framework (AI RMF 1.0), 1(1). https://doi.org/10.6028/nist.ai.100-1

Ramos, H. M., Kuriqi, A., Coronado-Hernández, O. E., López-Jiménez, P. A., & Pérez-Sánchez, M. (2023). Are digital twins improving urban-water systems efficiency and sustainable development goals? Urban Water Journal, 1–13. https://doi.org/10.1080/1573062x.2023.2180396

Shyu, H.-Y., Castro, C. J., Bair, R. A., Lu, Q., & Yeh, D. H. (2023). Development of a Soft Sensor Using Machine Learning Algorithms for Predicting the Water Quality of an Onsite Wastewater Treatment System. ACS Environmental Au, 3(5), 308–318. https://doi.org/10.1021/acsenvironau.2c00072

WHO. (2022). Guidelines for drinking-water quality (4th ed.). World Health Organization. https://iris.who.int/bitstream/handle/10665/352532/9789240045064-eng.pdf?sequence=1

DISEÑO DE MATERIALES Y TECNOLOGÍAS EMERGENTES PARA LA REMOCIÓN DE CONTAMINANTES DEL AGUA A TRAVÉS DE LA IA

CAROLINA LEYVA
Instituto Politécnico Nacional, CICATA;

ENRIQUE NAVARRO
Universidad Tecnológica de Izúcar de Matamoros, Puebla;

LAURA GONZÁLEZ, EDUARDO SÁNCHEZ
Instituto Politécnico Nacional, CIIDIR Durango

Laboratorio Nacional de Ciencia, Tecnología y Gestión Integrada del Agua (LNAgua)

ARTÍCULO

Resumen

La Inteligencia Artificial (IA) está revolucionando el desarrollo de tecnologías y materiales para la remoción de contaminantes del agua, actuando como un coprocesador de diseño que redefine los enfoques tradicionales. Mediante técnicas como el machine learning (ML) y el diseño generativo, la IA acelera el descubrimiento de materiales avanzados (como MOFs, nanomateriales, membranas de filtración, etc.) optimizados para adsorber o degradar contaminantes específicos, desde metales pesados hasta microplásticos y PFAS. Además, optimiza procesos complejos como la oxidación avanzada, los reactores electroquímicos inteligentes y los sistemas híbridos autónomos, haciendo el tratamiento del agua más eficiente, asequible y sostenible. Aunque persisten desafíos como la necesidad de datos de calidad y la integración de infraestructura, la IA es clave para una gestión hídrica circular y resiliente.

Introducción

Las herramientas de la IA se han utilizado cada vez más para proteger contra amenazas ambien-

tales, garantizar la calidad del agua y optimizar el tratamiento de aguas residuales. En la Figura 1, se pueden observar las áreas de oportunidad de la IA en el sector hídrico. El desarrollo de nuevas tecnologías de remoción de contaminantes mediante IA representa la frontera más avanzada de la ingeniería ambiental. No es solo una herramienta de optimización; es un coprocesador de diseño que está redefiniendo cómo se conciben, crean y validan las soluciones de tratamiento.

Su capacidad para analizar grandes volúmenes de datos, encontrar patrones complejos y optimizar procesos en tiempo real la convierte en una herramienta invaluable. Para lograr esto, emplea un conjunto diverso de métodos integrados. Las categorías de modelos de IA más relevantes para el sector del agua son las Redes Neuronales Artificiales (ANN), que imitan las relaciones no lineales complejas; el Aprendizaje Automático (Machine Learning ML), que desarrolla modelos predictivos a partir de datos; y los Algoritmos de Búsqueda (SA), que optimizan sistemas mediante métodos inspirados en la evolución natural (Chowdhury, 2024).

Figura 1. Ramas del sector hídrico que pueden ser apoyadas por la IA

Materiales avanzados

Herramientas empleadas por la IA para el diseño de materiales avanzados

Uno de los aportes más significativos de la IA es en el diseño de materiales avanzados para la adsorción, catálisis y filtración de contaminantes. Desataca el diseño de materiales adsorbentes como esponjas de

nanoarcillas, hidrogeles o estructuras metal-orgánicas (MOFs), que son aplicados en la remoción de metales pesados o contaminantes emergentes (microplásticos, PFAS) (Mathaba, 2023; El Alaoui, 2023; Duarte, 2023). Para lograr este objetivo, a la IA hace uso de modelos complementarios a través de modelos de machine learning (ML) de la siguiente forma:

- **Predicción de Propiedades y Desempeño:** Se entrenan modelos de ML con bases de datos de propiedades químicas (porosidad, carga superficial, afinidad química). El modelo aprende la relación entre la estructura y la función, permitiendo predecir el desempeño de materiales virtuales nuevos. Esto permite cribar millones de estructuras en horas, usando técnicas como Redes Neuronales de Grafos (GNNs), Random Forest o Support Vector Machines (SVM).
- **Diseño Generativo de Materiales:** En lugar de predecir, a la IA se le da un objetivo (ej., diseñar un material con alta capacidad de adsorción de PFAS y bajo costo). Usando modelos como las Generative Adversarial Networks (GANs), la IA "imagina" y propone estructuras atómicas completamente nuevas y a menudo contra-intuitivas.
- **Optimización Multi-objetivo:** Un material debe ser efectivo, barato, reusable y estable, algoritmos de optimización (como NSGA-II) encuentran el óptimo compromiso entre todas estas variables, presentando un abanico de soluciones para una decisión informada.

Tipos de materiales que se están diseñando con IA

- **Estructuras porosas avanzadas (MOFs y COFs)**: La IA predice qué combinaciones de metales y ligandos crearán poros con la química perfecta para adsorber un contaminante específico (Zheng, 2023).
- **Nanomateriales y compuestos:** La IA optimiza el doping de nanoplacas de grafeno o diseña nanocompuestos (ej., óxido de hierro con biochar) para combinar alta adsorción con propiedades magnéticas para una fácil separación (Duarte, 2023).

- **Fotocatalizadores:** Para destruir contaminantes, la IA diseña catalizadores (como TiO2 dopado) que bajo luz visible generan radicales libres que los degradan, haciéndolos activos bajo luz solar y más eficientes (Olawade, 2024).
- **Optimización de Membranas de Filtración:** La IA modela cómo la estructura química y la topografía de una membrana afectan su eficiencia, resistencia al fouling (ensuciamiento) y selectividad, resultando en membranas más duraderas y que consumen menos energía (Shahouni, 2024).

Tecnologías Emergentes Impulsadas por IA

La IA no solo diseña materiales, sino que también optimiza cómo se usan en procesos complejos. El gran número de variables que influyen en la eficacia del tratamiento de aguas residuales dificulta predecir el resultado de un proceso que aún no ha sido probado. Sin embargo, los modelos de aprendizaje automático se han aplicado con éxito en algunos estudios relacionados con plantas de tratamiento de aguas residuales para predecir la concentración del efluente a partir de las cargas influentes y las condiciones operativas (Collado, 2024).

- **Procesos de Oxidación Avanzada (POA):** Estos procesos usan reactivos y catalizadores para generar radicales libres que degradan contaminantes persistentes. La IA modela y optimiza las dosis de reactivos, el pH y el tiempo de residencia para maximizar la degradación minimizando costos y subproductos tóxicos. Esto incluye el diseño de fotocatalizadores para luz visible y el uso de gemelos digitales para optimizar la geometría de los reactores, creando sistemas de desinfección solar ideales para comunidades remotas (Hübner, 2024).
- **Sistemas híbridos multi-etapa con control cognitivo:** Combinan varias tecnologías en serie (ej.: ozonización + biofiltros con bacterias especializadas + adsorbentes avanzados), usando modelos de optimización se decide, en tiempo real, cómo distribuir la carga de agua entre las diferentes etapas. Por ejemplo, si un sensor detecta un pico de amonio, deriva más

flujo hacia la etapa de nitrificación biológica, o para la dosificación precisa de reactivos, la IA calcula la dosis exacta de ozono o coagulante necesaria. Las plantas de tratamiento modulares y ultracompactas que pueden adaptarse para remover cualquier tipo de contaminante de manera específica (Lowe, 2022).

- **Membranas de separación de próxima generación:** Membranas de ósmosis inversa, nanofiltración o grafeno. El diseño generativo crea estructuras de poros con formas y cargas superficiales específicas para bloquear selectivamente iones específicos (ej.: borato, nitrato) mientras deja pasar otros, algo imposible con métodos tradicionales. Autolimpieza predictiva: Sensores de presión y flujo alimentan modelos de ML que detectan los patrones incipientes de fouling. El sistema puede entonces invertir automáticamente el flujo, cambiar el pH o liberar una nano-burbuja de aire para limpiar la membrana antes de que se ensucie críticamente. Esto representaría membranas con una vida útil hasta un 50% mayor y menor consumo de energía, abaratando la desalación y el reúso de agua (Safeer, 2022)

Desafíos y Futuro

Persisten desafíos significativos, la IA necesita grandes cantidades de datos de alta calidad para aprender, lo que requiere una colaboración crucial entre universidades, empresas y gobiernos para crear bases de datos abiertas. Además, los costos de implementación, operación y el impacto ambiental de estos sistemas avanzados deben ser considerados. El siguiente paso evolutivo es que la IA no solo optimice la remoción, sino que diseñe tecnologías que implementen activamente los principios de la economía circular en la gestión del agua.

Figura 2. Desafíos y futuro de la IA en el desarrollo de tecnologías aplicadas

Conclusión

Al permitir el diseño racional de materiales, la optimización de procesos complejos y la personalización de soluciones, la IA está ayudando a resolver algunos de los problemas más desafiantes de la contaminación hídrica. Está actuando como el arquitecto principal de una nueva generación de tecnologías de tratamiento que son adaptativas, resilientes e increíblemente eficientes. Este es el camino hacia una verdadera gestión circular y sostenible del agua. Sin embargo, este poder con lleva grandes responsabilidades, por lo que es necesario un compromiso con un uso ético, transparente y respetuoso con las personas y el medio ambiente.

Bibliografía

Chowdhury S., Karanfil T. (2024). Applications of artificial intelligence (AI) in drinking water treatment processes: Possibilities, Chemosphere, 356, 141958, doi.org/10.1016/j.chemosphere.2024.141958

Collado I. (2024). https://www.group.sener/insights/ia-machine-learning-disciplinas-del-agua-medioambiente-del-hidrologo-al-hidroinformatico/

Duarte M.S., Martins G.(2023). A Review of Computational Modeling in Wastewater Treatment Processes. ACS EST Water 4 (3) 784-804. doi.org/10.1021/acsestwater.3c00117

El Alaoui El Fels, A., Mandi, L., Kammoun, A. (2023). Artificial Intelligence and Wastewater Treatment: A Global Scientific Perspective through Text Mining. Water, 15(19), 3487. doi.org/10.3390/w15193487

Hübner U, Spahr S., Lutz H., Wieland A., Rüting S. (2024). Advanced oxidation processes for water and wastewater treatment – Guidance for systematic future research, Heliyon, 10 (9), 2024, e30402, doi.org/10.1016/j.heliyon.2024.e30402

Lowe, M., Qin, R., & Mao, X. (2022). A Review on Machine Learning, Artificial Intelligence, and Smart Technology in Water Treatment and Monitoring. Water, 14(9), 1384. https://doi.org/10.3390/w14091384

Mathaba, M., Banza, J. (2023). A comprehensive review on artificial intelligence in water treatment for optimization. Clean water now and the future. Journal of Environmental Science and Health, Part A, 58(14), 1047–1060. doi.org/10.1080/10934529.2024.2309102

Olawade D.B., Ige A.O., Olaremu A.G. (2024). The synergy of artificial intelligence and nanotechnology towards advancing innovation and sustainability - A mini-review. Nano Trends 8,100052, doi.org/10.1016/j.nwnano.2024.100052

Safeer S, Pandey R.P, Rehman B, Safdar T, Ahmad I, Hasan S.W., Ullah A. (2022). A review of artificial intelligence in water purification and wastewater treatment: Recent advancements, Journal of Water Process Engineering, 49, ,102974, doi.org/10.1016/j.jwpe.2022.102974

Shahouni, R., Abbasi, M., Dibaj, M., Akrami, M. (2024). Utilising Artificial Intelligence to Predict Membrane Behaviour in Water Purification and Desalination. Water, 16(20), 2940. doi.org/10.3390/w16202940

Zheng Z., Yaghi O. M. (2023). A GPT-4 Reticular Chemist for Guiding MOF Discovery. Angewandte Chemie 62 (46) e202311983. doi.org/10.1002/anie.202311983

DESARROLLO DE UNA METODOLOGÍA BASADA EN INTELIGENCIA ARTIFICIAL PARA PREDECIR NITRÓGENO Y FÓSFORO EN CUERPOS DE AGUA SUPERFICIALES MEDIANTE PARÁMETROS IN SITU Y DE BAJO COSTO

MARCO ELENES ALDERETE, HECTOR RODRIGUEZ-RANGEL, JOSÉ LUIS MEDINA JIMÉNEZ, LEONEL AMABILIS SOSA
Instituto Tecnológico de Culiacán, Sinaloa

LUIS ALBERTO MORALES-ROSALES
Facultad de ingeniería civil, SECIHT,
Universidad Michoacana de San Nicolás de Hidalgo

Resumen

La inteligencia artificial (IA) incursiona progresivamente en las áreas técnicas y científicas. Para una apropiada gestión del recurso hídrico, las aplicaciones de la IA deben estar a cargo de un grupo multidisciplinario que incluya a expertos en agua y computacionales. En este trabajo se desarrolla un modelo predictivo para la estimación de nitrógeno (N_TOT) y fósforo (P_TOT) totales en cuerpos de agua superficiales, utilizando parámetros medibles in situ como temperatura, turbidez, pH. La metodología incorpora técnicas de aprendizaje automático, incluyendo simulaciones de Monte Carlo y algoritmos de preprocesamiento de datos. Con más de 22,000 registros de la Red Nacional de Monitoreo de Calidad del Agua en México. Los modelos alcanzaron valores de R^2 superiores a 0.97. El enfoque propuesto ofrece una alternativa económicamente viable y escalable, con potencial de reducir costos de monitoreo en más del 60%, manteniendo la confiabilidad para una mejor gestión del recurso hídrico.

Introducción

La gestión de la calidad del agua enfrenta retos significativos debido a los costos y tiempos asociados a los análisis de laboratorio, particularmente en la medición de nutrientes clave como nitrógeno y fósforo. Estos elementos son fundamentales para evaluar el estado trófico y la salud de los ecosistemas acuáticos (Conley et al., 2009; World Health Organization, 2017). Sin embargo, la determinación de ambos nutrientes con los métodos actuales (i.e. de laboratorio) implica gastos de 75 a 200 USD por muestra, además de costos de transporte y tiempos de espera considerables. En regiones con recursos limitados, este esquema dificulta el monitoreo constante y de amplia cobertura.

Por otra parte, existen parámetros de calidad del agua de seguimiento, mayoritariamente fisicoquímicos (p.ej. temperatura, pH, conductividad), que son fáciles, rápidos, y, de especial interés, de bajo costo. Con los métodos estadísticos convencionales, prácticamente no existe relación que permita establecer modelos predictivos de nitrógeno y fósforo, utilizando como variables de entrada o independientes los parámetros de fácil acceso.

Por su parte, la inteligencia artificial (IA) y el aprendizaje automático (ML) han mostrado potencial para estimar concentraciones de nutrientes a partir de variables indirectas como turbidez, pH, sólidos disueltos y temperatura (Zhang et al. 2020). Estos enfoques permiten generar resultados rápidos, económicos y escalables, con aplicaciones en la toma de decisiones y en la planeación de políticas públicas.

El objetivo de este trabajo es presentar una metodología sistemática y escalable para predecir las concentraciones de nitrógeno total (N_TOT) y fósforo total (P_TOT) a partir de parámetros fácilmente medibles, utilizando algoritmos de aprendizaje automático validados en condiciones heterogéneas.

Desarrollo

Área de estudio y datos

El estudio se centró en la región del Pacífico mexicano, utilizando registros de la Red Nacional de Monitoreo de Calidad del Agua (RENAMECA). Se

analizaron más de 22,000 registros recolectados entre 2010 y 2022, distribuidos en Sinaloa, Jalisco, Michoacán y Nayarit. Cada registro incluyó parámetros fisicoquímicos, biológicos y ambientales, de los cuales se seleccionaron siete variables clave por su adquisición con sensores de campo: N-NH3, N-NO2, N-NO3, sólidos disueltos totales, pH en campo, turbidez y temperatura ambiente.

Metodología

El flujo metodológico incluyó: (i) selección de variables medibles in situ, (ii) preprocesamiento de datos mediante técnicas de balanceo como SMOTE, ADASYN y bootstrapping (Chawla et al., 2002), (iii) normalización con MinMaxScaler y StandardSca-

Algoritmo	Idea principal	Ventajas	Limitaciones
Random Forest	Construye muchos árboles de decisión y combina sus resultados (votación o promedio).	Robusto, maneja bien datos ruidosos, evita sobreajuste.	Puede ser lento en grandes conjuntos, menos interpretable.
Extra Trees	Similar a Random Forest, pero con más aleatoriedad en cada punto de decisión.	Más rápido que RF, buena precisión.	Menos interpretable, puede ser menos estable.
Gradient Boosting	Los árboles se construyen uno tras otro, corrigiendo los errores previos.	Alta precisión, detecta relaciones complejas.	Más lento, sensible a hiperparámetros.
HistGradientBoosting	Usa histogramas para acelerar la construcción de árboles.	Muy eficiente en datos grandes, buen desempeño.	Menos intuitivo para interpretar.
XGBoost	Entrena varios modelos débiles de forma secuencial, donde cada nuevo modelo se enfoca en corregir los errores del modelo anterior, para lograr una predicción final muy precisa y potente.	Precisión alta, rápido, estándar en competencias.	Complejo de ajustar, más difícil de interpretar.
LightGBM	Divide en hojas en vez de niveles, lo que lo hace más rápido.	Escalable, muy rápido, excelente en grandes datos.	Puede sobreajustar en datos pequeños, menos interpretable.
CatBoost	Optimizado para trabajar con variables categóricas sin preprocesamiento.	Maneja datos mixtos, reduce necesidad de codificación.	Más nuevo, menos conocido en algunas áreas.
MLP Regressor	Red de "neuronas" conectadas que aprenden patrones complejos.	Captura relaciones no lineales, flexible.	Necesita más datos, menos interpretable, sensible a parámetros.

Tabla 1. Descripción de los diferentes algoritmos de Inteligencia Artificial evaluados.

ler, y (iv) partición de datos en esquemas 70/30 y 80/20.

Se entrenaron modelos con ocho algoritmos de aprendizaje supervisado, incluyendo Random Forest, Extra Trees y MLP Véase Tabla 1. El desempeño fue evaluado mediante simulaciones de Monte Carlo para reducir el sesgo aleatorio y obtener métricas robustas. Posteriormente, se aplicó optimización bayesiana con Optuna para refinar hiperparámetros y mejorar la capacidad predictiva (Bergstra et al., 2011).

Como se puede observar, se hace uso de técnicas de IA, ML y estadísticas, tanto de manera secuencial como de retroalimentación entre sí.

Resultados

Los modelos basados en árboles de decisión, particularmente Extra Trees y Random Forest, mostraron el mejor desempeño con valores de R^2 superiores a 0.97 en validación interna. La validación externa con registros de Sonora y Oaxaca (conjunto de datos de calidad del agua no considerados durante el desarrollo ni entrenamiento de los modelos) confirmó la capacidad de generalización del modelo, con una ligera disminución en la precisión véase Figura 1 y Figura 2.

En términos económicos, se estimó que el uso de sensores in situ y modelos predictivos podría reducir en más del 60% los costos anuales asociados al monitoreo convencional, lo cual representa una ventaja considerable para programas de gestión hídrica a gran escala.

Comparado con estudios internacionales basados en imágenes satelitales o en bases de datos extensivas, este enfoque ofrece un balance óptimo entre precisión, costo y aplicabilidad operativa.

Conclusiones

La principal contribución de este trabajo radicó en demostrar que los modelos de aprendizaje automático pueden ser utilizados en paralelo a los análisis de laboratorio, para que la carga de trabajo en estos sea menor.

Los modelos predictivos desarrollados permiten estimar con alta precisión ($R^2 > 0.97$) las concentraciones de nitrógeno y fósforo totales a

Figura 1. Comparativa de valores reales contra los predichos del estado de Oaxaca para el nitrógeno total.

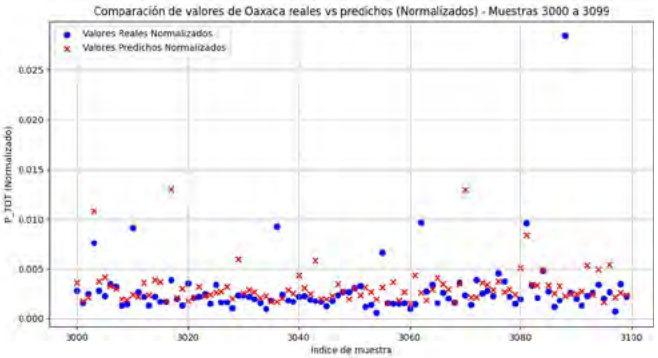

Figura 2. Comparativa de valores reales contra los predichos del estado de Sonora para el fósforo total.

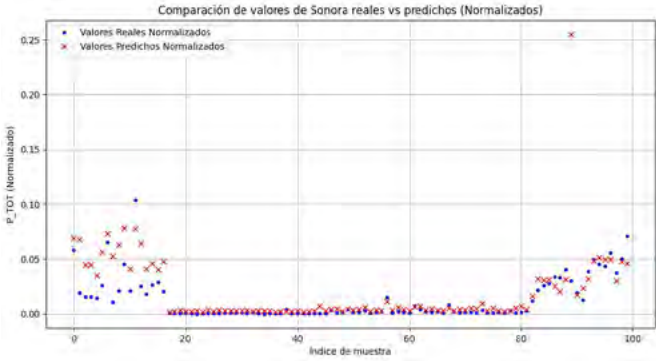

partir de parámetros medibles en campo mediante sensores de bajo costo. Esto representa una alternativa viable a los métodos de laboratorio, con la posibilidad de reducir en más del 60% los costos de monitoreo. Sin embargo, aún existen limitaciones: no se incorporaron variables biológicas como clorofila-a o indicadores de oxígeno disuelto, los cuales enriquecerían la interpretación ecológica. Futuras investigaciones podrían integrar estas variables, así como expandir la validación hacia climas y regiones con dinámicas distintas.

La metodología es escalable, adaptable a distintos cuerpos de agua y útil para agencias gubernamentales, instituciones académicas y organismos operadores de agua. Con su integración en plataformas digitales, estos modelos pueden convertirse en herramientas clave para el seguimiento en tiempo

real y la toma de decisiones en la gestión sostenible de los recursos hídricos.

Bibliografía

Bergstra, J., Bardenet, R., Bengio, Y. & Kégl, B. (2011). Algorithms for Hyper-Parameter Optimization. Advances in Neural Information Processing Systems, 24, 2546–2554.

Chawla, N. V., Bowyer, K. W., Hall, L. O. & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. Journal of Artificial Intelligence Research, 16, 321–357.

Conley, D. J., Paerl, H. W., Howarth, R. W., Likens, G. E., Boesch, D. F., Seitzinger, S. P., Havens, K. E. & Lancelot, C. (2009). Eutrophication: Too much of a good thing has gone global. Environmental Science & Technology, 43 (5), 1610–1612.

Zhang, G., Li, Y., Gao, X., Hou, Y. & Liang, Q. (2020). Prediction of chlorophyll-a concentration in multiple lakes based on machine learning. Ecological Indicators, 117, 106649.

World Health Organization. (2017). Guidelines for Drinking-water Quality: Fourth Edition. Geneva: WHO.

¿IA PARA MANEJO DEL AGUA O AGUA PARA LA IA? CONCIENCIA E INFORMACIÓN PARA LA TOMA DE DECISIONES RESPONSABLES

MARISSA MAR PECERO, DAVID-EDUARDO GUEVARA-POLO

ARTÍCULO

Resumen

La creciente demanda por servicios digitales y de inteligencia artificial (IA) ha generado preocupaciones sobre su efecto en los recursos hídricos. En marzo de 2025, la empresa OpenAI reconoció públicamente la necesidad de limitar el uso de ChatGPT por sobrecarga en su infraestructura. La IA requiere agua en tres etapas: enfriamiento de centros de datos, generación eléctrica y manufactura de servidores. Cada búsqueda con IA puede consumir hasta 50 ml de agua. En México, Querétaro concentra gran parte del consumo energético y de agua para centros de datos, con un consumo anual de hasta 15 mil millones de litros. Ante este panorama, se destaca la importancia de la transparencia empresarial, el derecho a la información y la adopción de mejores prácticas. Iniciativas globales buscan una gestión sostenible del agua, involucrando a empresas tecnológicas, sociedad civil y gobiernos.

Introducción

La conciencia sobre el cuidado del agua suele surgir mayormente ante eventos extremos como inundaciones y sequías. En el caso de la ciudadanía, no se ha logrado que se entienda mejor la demanda de agua, sobre todo indirecta, como consumidores de productos o servicios, lo que nos hace corresponsables en las respectivas huellas hídricas.

Un caso que ejemplifica esto ocurrió en marzo de 2025, cuando la demanda global de imágenes generadas por inteligencia artificial (IA) en la herramienta ChatGPT provocó una sobrecarga en la infraestructura de la empresa desarrolladora y operadora, Open AI. Su director lo reconoció públicamente, al declarar la necesidad de introducir límites de uso de esta herramienta. (Sam Altman on X, 2025).

En este contexto, el objetivo del presente texto es describir razones técnicas que explican el uso de agua en los centros de datos, presentar hallazgos de la literatura especializada sobre este tema, reflexionar sobre diferentes ámbitos en torno al uso responsable de la IA y enfatizar la importancia de la transparencia por parte de las empresas del sector tecnológico.

Las razones de una IA sedienta

De acuerdo con Cisco (2025), un centro de datos es una instalación física que las organizaciones utilizan para almacenar sus aplicaciones y datos críticos.

En la actualidad, caracterizada por la proliferación de las redes sociales, el auge de las telecomunicaciones y la ubicuidad del internet, la generación, procesamiento y almacenamiento de datos es una necesidad indiscutible. En particular, los modelos de inteligencia artificial (IA) requieren de grandes volúmenes de datos para entrenarse, ya que, esencialmente, lo que un modelo hace es una serie muy grande de operaciones matemáticas con el fin de encontrar patrones en un conjunto de datos.

De acuerdo con Li et al (2025), el uso del agua para la inteligencia artificial se distribuye en tres etapas: el enfriamiento de los centros de datos, el uso de agua para la generación de electricidad fuera de sitio y el agua empleada para el proceso de manufactura de los servidores. Vale la pena señalar que la huella hídrica se divide en azul (agua superficial y subterránea), verde (lluvia y humedad del suelo) y gris (necesaria para asimilar contaminantes) (Water Footprint Network, s.f.)

Ahora bien, de acuerdo con Li et al (2025), el enfriamiento sucede en dos etapas: En la primera, el calor de los servidores es transferido a su rede-

dor, dentro de las instalaciones del centro de datos. En la segunda etapa se transfiere el calor de las instalaciones al exterior. La selección de los métodos e infraestructura de enfriamiento para los servidores (Figura 1) es clave para la determinación de la huella hídrica y eficiencia de los Centros de Datos.

¿Cuántas gotas por una respuesta?

Vale la pena aplicar el concepto de huella hídrica a la inteligencia artificial.

Por ejemplo, una estimación realizada por Hannah et al (2025) de la Universidad de Birmingham indica que cada búsqueda con IA representa 50 ml, es decir, la quinta parte de un vaso de agua. En el caso de México, una estimación para ChatGPT-3 sugiere un consumo de 24 ml por búsqueda (Li, et al 2025).

La atención a este asunto no es reciente. Actores desde el ámbito académico (Mytton, 2021) de organismos multilaterales (OCDE, 2023; (ITU, 2014; ITU, 2022; World Bank, 2023) y la propia industria reconocen el uso intensivo de agua y energía en los centros de datos

Figura 1. Elaboración propia con datos de Nabiax (2023), Nvent (s.f.) y Abast (2024)

Según McKinsey (2024), los centros de datos actualmente utilizan 60 GW y antes del 2030 podrían demandar entre 171 y hasta 298 GW anuales. Análogamente, Li et al (2025) proyectan que la demanda global de IA represente entre 4,200 y 6,600 millones de metros cúbicos de extracción de agua en 2027, lo que supera la extracción anual total de agua de la mitad del Reino Unido.

En México, García Gasca (2025) considera que Querétaro, "concentra aproximadamente el 50% de la capacidad energética nacional destinada a centros de datos, actualmente de 305 MW y con consumo de caso 9 mil millones de litros de agua al año. Además, se proyecta para soportar un consumo de 600 MW, lo que significaría un consumo de 15 mil millones de litros de agua al año".

¿Qué hacer al respecto?

En el sector industrial, el abastecimiento de agua puede ocurrir de dos maneras: autoabastecimiento o conexión a la red de agua potable. En el primer caso, se debe tener un título de concesión otorgado por la Comisión Nacional del Agua para extraer el agua (típicamente mediante pozos) y en el segundo caso, la industria debe tener un contrato con el organismo operador local (público, privado o mixto).

Ahora bien, dada la necesidad de garantizar el agua para consumo humano, el creciente interés de la población, la academia (ver Figura 2) y otros actores sociales por conocer el impacto ambiental

Figura 2. Cantidad de publicaciones académicas indizadas en Scopus relacionadas con el uso de agua y los centros de datos

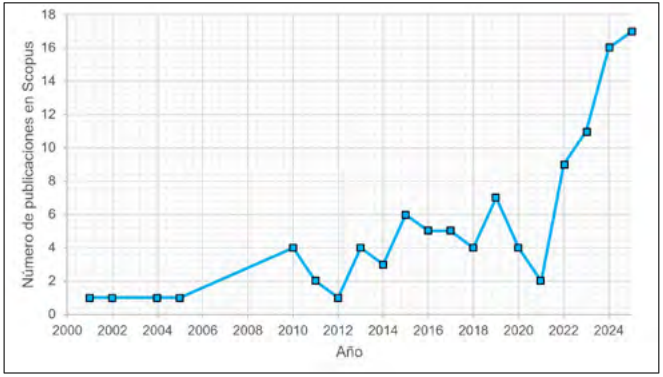

de los centros de datos, se encuentra legítimamente sustentado en el derecho a la información en su doble vertiente: el derecho a informar y ser informado, que por lo señalado en el párrafo anterior, esa responsabilidad recae inicialmente en los organismos encargados, por un lado de la administración, y por otro, del abastecimiento de agua.

En ese contexto, destaca la actualización de análisis de la OCDE (2024) sobre la gobernanza hídrica en México -esta vez en el contexto de las

oportunidades derivadas del nearshoring-, el cual reitera la recomendación de mejorar el sistema de información sobre el agua para garantizar que se proporcionen datos precisos y actualizados sobre su disponibilidad, uso y calidad.

Por su parte, la industria desarrolla mejores prácticas para el manejo responsable del agua, además del cumplimiento de la legislación nacional y estándares internacionales, porque su sostenibilidad depende de lo que sucede en la cuenca donde están ubicadas sus plantas, pero también de las operaciones de toda su cadena de suministro.

En el caso de la que nos ocupa, es notable el incremento de empresas del sector de telecomunicaciones que en los últimos cinco años se han adherido al Mandato de Directores de Empresas sobre el Agua del Pacto Mundial Global de las Naciones Unidas, creado en 2007. Actualmente, este compromiso cuenta con el involucramiento de 54 empresas del sector tecnológico en 26 países.

Además de ese compromiso, existe una Alianza global de empresas, organizaciones de la sociedad civil y sector público (AWS) que trabaja de manera colaborativa para la gestión sostenible del agua en sitio y en escala de cuenca. Entre sus áreas prioritarias de acción se encuentra el sector de tecnología y microelectrónica, dicha alianza impulsó también la creación del Estándar Internacional de Gestión Sostenible del Agua con un enfoque importante de transparencia.

Figura 3.

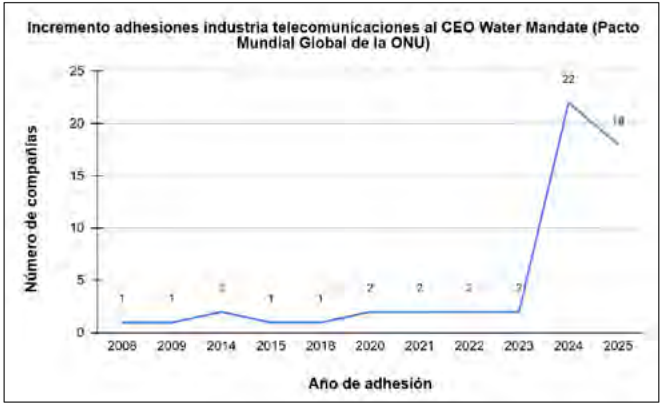

Fuente: análisis propio, con información de UN Global Compact and Pacific Institute (2025)

Conclusión

Los servicios digitales y de telecomunicaciones son servicios habilitadores para el desarrollo económico y ejercicio de otros Derechos Humanos, -en este caso, también para mejorar la gestión del agua-. Sin embargo, el uso de éstos debe acompañarse de una conciencia clara sobre su huella hídrica y ambiental. Ese uso responsable debe basarse en información relevante y ser traducida en acción gubernamental y de la industria, pero también de los consumidores.

Bibliografía

Abast. (26 de julio de 2024). Refrigeración en los Centros de Datos: Métodos y Tendencias Actuales. Obtenido de https://www.abast.es/blog/refrigeracion-en-los-centros-de-datos-metodos-y-tendencias-actuales/

Cisco. (2025). What is a data centre? Obtenido de Cisco: https://www.cisco.com/c/en_uk/solutions/data-center-virtualization/what-is-a-data-center.html

Garcia Gasca, T. (24 de julio de 2025). Ciencia y sociedad / Data Centers: consumo de agua real para inteligencia artificial. Diario de Queretaro. Obtenido de https://oem.com.mx/diariodequeretaro/analisis/ciencia-y-sociedad-data-centers-consumo-de-agua-real-para-inteligencia-artificial-24896897

Hannah, D. (2025). Applications of artificial intelligence for water. Evento de 50 aniversario del PHI-UNESCO.

ITU. (2014). Best practices for green data centres. Obtenido de https://www.itu.int/rec/T-REC-L.1300/en

ITU. (2022). Environmental efficiency and impacts on United Nations Sustainable Development Goals of data centres and cloud computing. Obtenido de https://www.itu.int/itu-t/recommendations/rec.aspx?id=15216&lang=en

Li, P., Yang, J., Islam, M. A., & Ren, S. (2025). Making AI Less "Thirsty": Uncovering and Addressing the. Communications of the ACM, 68(7), 54-61. doi:https://doi.org/10.48550/arXiv.2304.03271

McKinsey & Company. (29 de octubre de 2024). AI power: Expanding data center capacity to meet growing demand. Obtenido de https://www.mckinsey.com/industries/technology-media-and-telecommunications/our-insights/ai-power-expanding-data-center-capacity-to-meet-growing-demand#/

Meade, R. (25 de agosto de 2025). México quiere ser líder en centros de datos para IA, pero no tiene la infraestructura energética. Obtenido de Wired: https://es.wired.com/articulos/mexico-quiere-ser-lider-en-centros-de-datos-para-ia-pero-no-tiene-la-infraestructura-energetica

Measuring the environmental impacts of artificial intelligence compute and applications: The AI footprint. (s.f.).

Mytton, D. (2021). Data centre water consumption. npj Clean Water, 4(11). doi:https://doi.org/10.1038/s41545-021-00101-w

Nabiax. (21 de agosto de 2023). Principales técnicas y sistemas de refrigeración en Centros de Datos. Obtenido de https://nabiax.com/principales-tecnicas-y-sistemas-de-refrigeracion-en-centros-de-datos/

Nvent. (s.f.). Todo lo que debes saber sobre enfriamiento para centros de datos. Obtenido de https://www.nvent.com/es-mx/hoffman/todo-lo-que-debes-saber-sobre-enfriamiento-para-centros-de-datos

OECD. (2022). Measuring the environmental impacts of artificial intelligence compute and applications. Obtenido de https://www.oecd.org/en/publications/measuring-the-environmental-impacts-of-artificial-intelligence-compute-and-applications_7babf571-en.html

OECD. (2024). OECD Economics Department Working Papers No. 1799. doi:https://dx.doi.org/10.1787/0ca7fc0a-en

Ren, S. (30 de noviembre de 2023). How much water does AI consume? The public deserves to know. Obtenido de OECD.AI Policy Observatory: https://oecd.ai/en/wonk/how-much-water-does-ai-consume

Sam Altman on X. (27 de marzo de 2025). Obtenido de X: https://x.com/sama/status/1905296867145154688

Sosa Santiago, M. (31 de marzo de 2025). Tendencia de Ghibli colapsa servidores de ChatGPT y derrocha millones de litros de agua. Obtenido de El Economist: https://www.eleconomista.com.mx/arteseideas/tendencia-ghibli-colapsa-servidores-chatgpt-derrocha-millones-litros-agua-20250331-752797.html

UN Global Compact and Pacific Institute. (2025). Endorsing Companies. Obtenido de CEO Water Mandate: https://ceowatermandate.org/about/endorsing-companies/

Water Footprint Network. (s.f.). Obtenido de Water Footprint: https://www.waterfootprint.org/water-footprint-2/

World Bank. (2023). Green data centers: towards a sustainable digital transformation. Obtenido de https://documents1.worldbank.org/curated/en/099112923171023760/pdf/P178597-0914e486-6950-40f6-8697-5b924ae2b4e1.pdf

Lineamientos para presentar artículos al *Impluvium*

1. La contribución debe ser un texto de **corte académico**, por lo que no debe personalizarse.

2. Los trabajos deben contener: título, nombre del autor o autores y su institución de adscripción, resúmen (de hasta 150 palabras), introducción, desarrollo, conclusiones y bibliografía consultada.

3. Las contribuciones deberán entregarse en formato de procesador de textos Microsoft Word, con letra Arial de 12 puntos e interlineado doble.

4. Los textos no deberán exceder **1,700 palabras**, incluyendo la bibliografía.

5. Las imágenes que deseen utilizarse en el texto se entregarán en archivo independiente en formato jpg a 150 dpi. En el documento de Word se referirán de la siguiente manera: Véase Figura 1.

6. Se utilizará el sistema de citas y referencias bibliográficas Harvard-APA. Este estilo presenta las citas dentro del texto del trabajo, utilizando el apellido del autor, la fecha de publicación y la página, por lo que no se requieren notas al pie de página. Ejemplo: (González Villarreal, 2013, p. 25).

7. Al final del trabajo la bibliografía se agrupará en el apartado "Bibliografía" y se colocará de la siguiente manera: autor, año de publicación (entre paréntesis), título, editorial y lugar de publicación. Ejemplo: González Villarreal, F. y Arriaga Medina, J. (2015). Expresiones de la inseguridad hídrica. Revista Ciudades, No. 105, Puebla, México.

8. Los editores realizarán una corrección de estilo y consultarán con los autores cualquier modificación sobre el contenido de la contribución.

9. El artículo debe enviarse al correo electrónico contacto@agua.unam.mx con el asunto **Articulo Impluvium: (tema)**.

Red del Agua
UNAM

Impluvium

Publicación digital de la Red del Agua UNAM
Número 32, Julio - Septiembre 2025
www.agua.unam.mx