

# Water Quality Analysis through Machine Learning and Deep Learning in IoT Systems: A Systematic Review

Ocaña-Velásquez, Jesús Daniel<sup>1</sup>, Dr.<sup>ID</sup>; Castro-García, José Heiner<sup>2</sup>, Mg.<sup>ID</sup>; Miranda-Saldaña, Rodolfo Junior<sup>3</sup>, Mg.<sup>ID</sup>

<sup>1,3</sup>Universidad Tecnológica del Perú, Chimbote, Perú, c25777@utp.edu.pe, c20312@utp.edu.pe, e20206@utp.edu.pe

*Abstract— The ecological quality of water is crucial for the protection of the aquatic environment and human health, and is affected by natural factors and, to a greater extent, by pollution resulting from industrialization, agriculture, and urbanization. This article presents a systematic review on the application of Machine Learning and Deep Learning in water quality analysis. The aim is to evaluate the effectiveness of Machine Learning and Deep Learning in water quality analysis, identifying accurate and reliable methods to develop advanced tools that facilitate the monitoring and prediction of this vital resource, thus improving its management and conservation. The PRISMA method was used to gather 65 significant articles related to water quality. The results suggest that Machine Learning and Deep Learning are fundamental in this field, particularly in studies conducted in China and India. The most common algorithms in Machine Learning are Random Forest and SVM, while in Deep Learning LSTM and CNN stand out. It is concluded that Machine Learning and Deep Learning are essential to assess water quality with IoT, the choice between the two depends on the availability of data and the objectives of the analysis, Machine Learning is preferable with limited data and limited resources, while Deep Learning is more effective with large volumes of data.*

**Keywords--** Machine Learning, Deep Learning, Water quality, Internet of Things (IoT).

# Análisis de la Calidad del Agua a Través de Machine Learning y Deep Learning en Sistemas IoT: Una Revisión sistemática

Ocaña-Velásquez, Jesús Daniel<sup>1</sup>, Dr.<sup>ID</sup>; Castro-García, José Heiner<sup>2</sup>, Mg.<sup>ID</sup>; Miranda-Saldaña, Rodolfo Junior<sup>3</sup>, Mg.<sup>ID</sup>  
<sup>1,3</sup>Universidad Tecnológica del Perú, Chimbote, Perú, c25777@utp.edu.pe, c20312@utp.edu.pe, e20206@utp.edu.pe

*Resumen— La calidad ecológica del agua es crucial para la protección del medio ambiente acuático y la salud humana, y se ve afectada por factores naturales y, en mayor medida, por la contaminación derivada de la industrialización, la agricultura y la urbanización. Este artículo presenta una revisión sistemática sobre la aplicación de Machine Learning y Deep Learning en el análisis de la calidad del agua. El objetivo es evaluar la efectividad de Machine Learning y Deep Learning en el análisis de la calidad del agua, identificando métodos precisos y confiables para desarrollar herramientas avanzadas que faciliten la monitorización y predicción de este recurso vital, mejorando así su gestión y conservación. Se utilizó el método PRISMA para reunir 65 artículos significativos relacionados con la calidad del agua. Los resultados sugieren que Machine Learning y Deep Learning son fundamentales en este campo, particularmente en estudios realizados en China e India. Los algoritmos más comunes en Machine Learning son Bosque Aleatorio y SVM, mientras que en Deep Learning destacan LSTM y CNN. Se concluye que Machine Learning y Deep Learning son esenciales para evaluar la calidad del agua con IoT, la elección entre ambos depende de la disponibilidad de datos y los objetivos del análisis, Machine Learning es preferible con datos limitados y recursos limitados, mientras que Deep Learning es más eficaz con grandes volúmenes de datos.*

*Palabras clave-- Machine Learning, Deep Learning, Calidad del agua, Internet de las Cosas (IoT).*

## I. INTRODUCCIÓN

La calidad ecológica del agua es fundamental para salvaguardar el medio ambiente acuático y la salud humana, siendo afectada por factores naturales y por la contaminación derivada de la industrialización, la producción agrícola y la vida urbana [1], [2], [3]. La contaminación del agua se debe a la presencia de compuestos químicos como metales pesados, pesticidas, colorantes sintéticos y compuestos orgánicos [4], [5]. La baja calidad del agua está relacionada con enfermedades diarreicas, infecciones gastrointestinales y un mayor riesgo de cáncer, especialmente en países de bajos ingresos y comunidades vulnerables. [6], [7], [8].

El desarrollo de tecnologías relacionadas con el Internet de las Cosas (IoT) y el análisis de datos a través de Machine Learning y Deep Learning permite llevar a cabo un análisis de la calidad del agua en tiempo real de manera más eficiente y precisa [9], [10].

Los algoritmos más comunes de Machine Learning incluyen la regresión lineal, el clasificador Bayesiano ingenuo, las máquinas de soporte vectorial (SVM), los árboles de decisión, el bosque aleatorio y el método de K vecinos más cercanos (KNN). Cada uno de estos algoritmos presenta características distintivas que los hacen idóneos para abordar una variedad de problemas específicos [11], [12].

Los algoritmos más utilizados en el campo del deep learning abarcan las Redes Neuronales Convolucionales (CNN), que son especialmente eficaces para el procesamiento de imágenes; las Redes Neuronales Recurrentes (RNN), ideales para el análisis de secuencias; y las Redes Neuronales de Memoria a Largo Plazo (LSTM), que permiten manejar dependencias a largo plazo en los datos [13], [14].

La monitorización de la calidad del agua es fundamental ante el aumento de la contaminación, requiriendo sistemas que detecten contaminantes en tiempo real. La integración de IoT, machine learning y deep learning ofrece soluciones innovadoras, pero presenta desafíos como la calidad de los datos y la ausencia de protocolos estandarizados. Superar estos obstáculos es vital para garantizar un control eficiente y preciso de la calidad del agua, así como para proteger los recursos hídricos, promoviendo un entorno más saludable y sostenible para las comunidades y el ecosistema.

El objetivo general de esta investigación es evaluar la efectividad de las técnicas de Machine Learning y Deep Learning en el análisis de la calidad del agua, con el fin de identificar métodos precisos y confiables que contribuyan al desarrollo de herramientas avanzadas para optimizar su monitorización y predicción, mejorando la gestión y conservación de este recurso vital.

Este documento está organizado en cinco partes: la primera examina investigaciones anteriores, la segunda expone la metodología empleada, la tercera muestra los resultados obtenidos, la cuarta analiza estos resultados y, por último, se presentan las conclusiones.

## II. TRABAJO RELACIONADO

El estudio [15] propone un modelo de Machine Learning que combina XGBoost y optimización bayesiana para predecir el índice de calidad del agua. La integración de datos sobre lluvias, flujo de arroyos y calidad del agua es fundamental, ya que proporciona información clave para mejorar las estrategias

de gestión hídrica en áreas similares. Esto es especialmente importante ante los desafíos del cambio climático, facilitando decisiones más precisas y sostenibles.

El estudio [16] se centra en capturar imágenes de los díales de medidores de agua, que se procesan mediante un algoritmo de detección de dígitos basado en aprendizaje profundo. Este proceso convierte las imágenes en datos numéricos y los envía a la nube para análisis en tiempo real, mejorando la precisión y confiabilidad del consumo de agua. Los resultados muestran una alta precisión en los datos, con mejoras significativas en métricas como el Error Cuadrático Medio (RMSE) y el Error Absoluto Medio (MAE) en el monitoreo de la calidad del agua.

Según [17] los métodos tradicionales de Deep Learning enfrentan desafíos para evaluar con precisión la calidad del agua en contextos de contaminación, especialmente en relación con la Puntuación de Contaminación por Nutrientes (NPS). Para abordar esta limitación, se ha desarrollado un nuevo modelo de aprendizaje profundo llamado Memoria de Corto Plazo Largo (LSTM), que busca mejorar la precisión en la predicción de la calidad del agua contaminada, ofreciendo una nueva perspectiva en la evaluación de la calidad del agua afectada por NPS.

En el estudio [18] se utilizaron algoritmos de Deep Learning, específicamente una Red Neuronal Convolucional combinada con un modelo LSTM (CNN-LSTM) y Boruta-XGB-CNN-LSTM, junto con técnicas de Machine Learning como MLP, KNN y XGBoost. Los resultados demostraron que el modelo Boruta-XGB-CNN-LSTM superó a otras metodologías en la predicción de la conductividad eléctrica en ambas estaciones. Se concluye que este enfoque combina técnicas eficientes, ofreciendo una metodología precisa y confiable para anticipar las variaciones en la conductividad eléctrica de los ríos, mejorando la gestión ambiental.

### III. METODOLOGÍA

En esta investigación, se emplea el método PRISMA, que facilita una documentación clara y detallada de la información obtenida de artículos relevantes sobre el tema.

#### A. Preguntas de Investigación

Se formularon cuatro preguntas de investigación empleando el modelo PICO.

RQ1: ¿Cuáles son las diferencias fundamentales entre las características de Machine Learning y Deep Learning en el análisis de la calidad del agua?

RQ2: ¿Cuáles son los algoritmos más utilizados de Machine Learning y Deep Learning para analizar la calidad del agua?

RQ3: ¿Cuáles son las principales limitaciones de las técnicas de Machine Learning y Deep Learning en el análisis de la calidad del agua en sistemas basados en IoT?

RQ4: ¿Cómo la integración de técnicas de Machine Learning y Deep Learning contribuye a mejorar el análisis de la calidad del agua?

#### B. Estrategia de búsqueda

La investigación utiliza una estrategia de búsqueda meticulosa en bases de datos reconocidas como Scopus, ScienceDirect, Web of Science, IEEE Xplore y EBSCOhost para identificar artículos relevantes. Se aplican criterios de inclusión y exclusión, según lo establecido en la Tabla 1 y en línea con la declaración PRISMA, para seleccionar los artículos que se analizarán en el estudio. La estrategia de búsqueda se enfoca en identificar artículos que incluyan el título, el resumen y las palabras clave de la siguiente manera:

(“Water quality” OR “drinking water” OR “Water Pollution” OR “water quality analysis” OR “Potable Water” OR “Water management”) AND (“machine learning” OR “Deep Learning”) AND (IoT OR “Internet of Things”) AND (monitoring OR prediction)

#### C. Criterios de inclusión y exclusión

Los criterios de inclusión y exclusión de esta revisión sistemática se detallan en la Tabla 1.

TABLA I  
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Criterios		
	Inclusión	Exclusión
Inclusión	I01	Artículos relacionados con Machine Learning o Deep Learning en el análisis de la calidad de agua.
	I02	Artículos que investigan el análisis de la calidad del agua mediante la aplicación de técnicas de Machine Learning y Deep Learning, a través de IoT.
	I03	Artículos en inglés
	I04	Artículos de los últimos 4 años (2021 -2024).
Exclusión	E01	Artículos que no guardan relación con el tema de investigación
	E02	Artículos que no tengan Open Access
	E03	Artículos que no guardan relación con Machine Learning o Deep Learning aplicados a la calidad del agua.

Se aplicó el método PRISMA en tres fases para la selección de artículos provenientes de cinco bases de datos, totalizando 1634 artículos. Después de eliminar 98 duplicados, se quedó con 1536 artículos. Posteriormente, al seleccionar únicamente aquellos de acceso abierto, se redujo el número a 226. Se realizó una revisión exhaustiva, descartando 103 artículos que no cumplían con los criterios de inclusión, lo que dejó un total de 126 para su evaluación. De estos, se eliminaron 58 por no estar relacionados con las preguntas de

investigación, lo que resultó en 65 artículos seleccionados para el desarrollo del estudio.

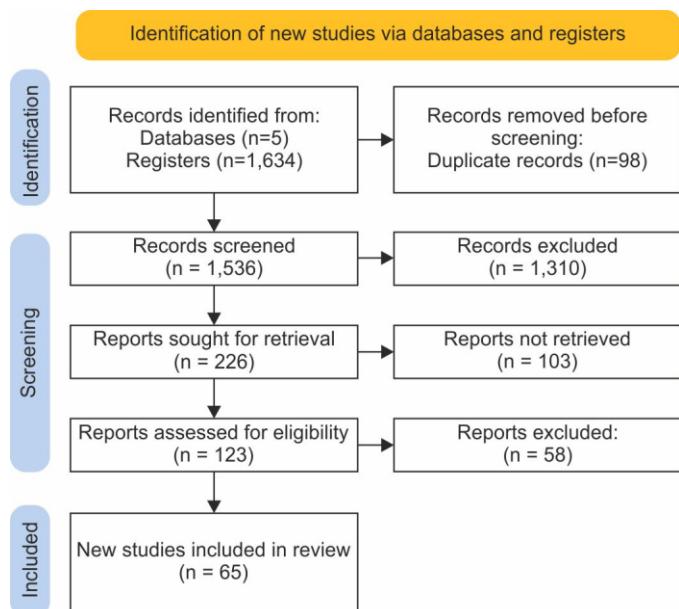


Fig. 1 Selección de artículos científicos con el método PRISMA

#### IV. RESULTADOS

Se realiza un análisis bibliométrico de 65 artículos.

##### A. Análisis bibliométrico

El análisis bibliométrico es un método cuantitativo que emplea herramientas matemáticas y estadísticas para detectar tendencias en un área de estudio. Utilizando VOSViewer, se llevó a cabo un análisis de investigaciones que generó redes de palabras clave y mapas visuales, lo que facilita la comprensión de los datos. Se revisaron 225 palabras clave, lo que resultó en la identificación de 17 términos clave.

Al examinar el mapa de la red presentado en la Figura 2, se pueden reconocer 17 palabras clave que muestran conexiones relevantes entre sí. El nodo “water quality” se relaciona estrechamente con “Machine Learning”, “Deep Learning” y “internet of things”. Respecto a “water quality” tiene conexión con “prediction”, “monitoring”, “water monitoring”, “real-time”, “sensor”, “potable water” y “water quality predictions”. En cuanto a “Machine Learning” presenta conexiones con “internet of things”, “water management”, “artificial intelligence” y “water quality monitoring”. Finalmente, el nodo “deep learning” está conectado con “water pollution”, “big data” y “algorithm”.

El nodo “wáter quality” está en el centro de una red conectándose con “machine learning”, “deep learning” e “Internet of Things”, lo que destaca la importancia de utilizar estas tecnologías para analizar la calidad del agua.

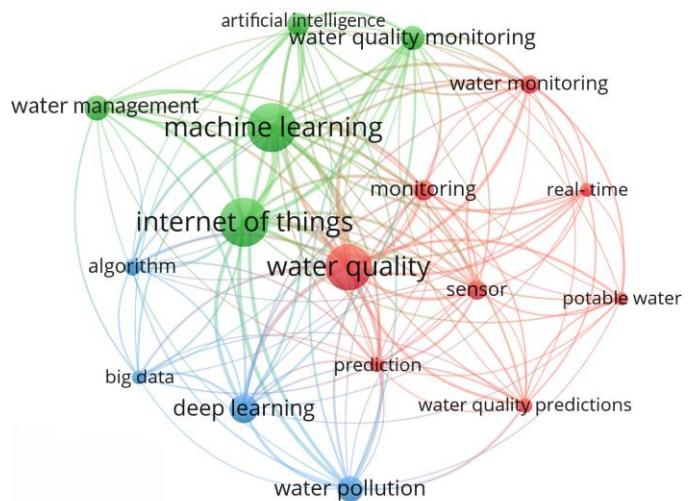


Fig. 2 Mapa bibliométrico de las relaciones entre palabras clave

##### B. Análisis de manuscritos

Se llevó a cabo un análisis de artículos en cinco bases de datos: Scopus, ScienceDirect, Web of Science, EBSCO Host e IEEE Xplore. En un principio, se encontraron 1,634 estudios, de los cuales se eliminaron 98 duplicados. Después de aplicar los criterios de inclusión y exclusión, se eligieron 65 estudios, como se ilustra en la Figura 3.

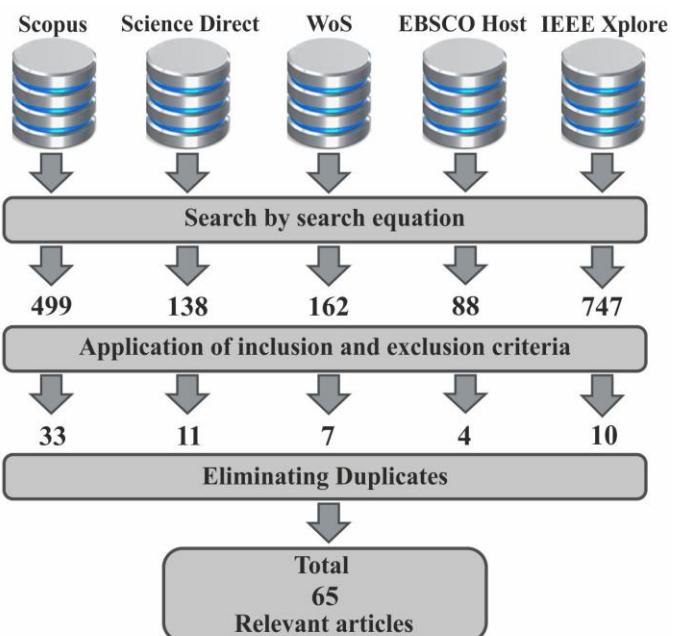


Fig. 3 Resultados obtenidos en la búsqueda.

La Figura 4 muestra una representación detallada del porcentaje de contribución informativa de diferentes bases de datos, donde Scopus se destaca al liderar con un impresionante 51% del total. Luego, Science Direct ocupa el segundo lugar con un 17%, IEEE Xplore contribuye con un 15%, Web of

Science aporta con un 11%, finalmente EBSCO Host contribuye con un 6%. La distribución porcentual destaca el impacto de cada base de datos y muestra las preferencias actuales en el acceso a información científica sobre la calidad del agua.

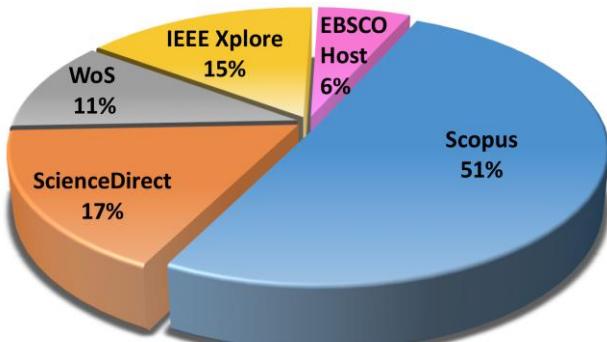


Fig. 4 Gráfico de resultados obtenidos en la búsqueda

Este estudio se enfoca en la contabilización anual de artículos publicados, seleccionados de acuerdo con ciertos criterios de inclusión, desde 2021 hasta 2024. En la Figura 5, se presenta un gráfico de barras que ilustra la cantidad y el porcentaje de artículos incluidos en la revisión sistemática, organizados por su año de publicación. Este aumento refleja un crecimiento notable en la producción académica relacionada con el tema, indicando una mayor atención y relevancia en esta área de investigación en los últimos años. Se registra un incremento significativo en el número de publicaciones durante este periodo, alcanzando su pico en 2024 con 26 artículos, lo que representa el 40.0% del total.

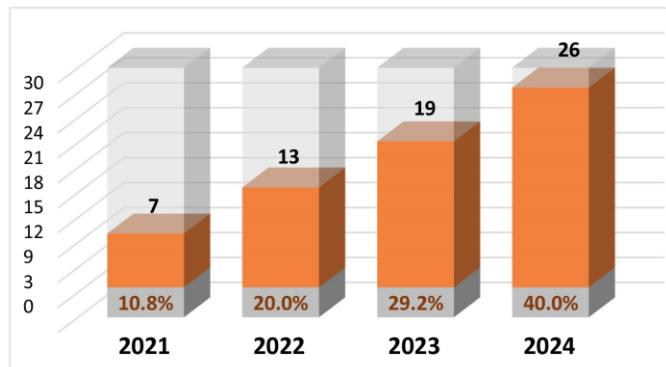


Fig. 5 Porcentajes de cantidad de artículos por año

La Figura 6 muestra el número de manuscritos publicados anualmente en varias bases de datos. En 2024, se observó un aumento significativo en las publicaciones, destacando Scopus con 13 artículos, seguido de ScienceDirect e IEEE Xplore con 4 cada uno. Web of Science registró 3 artículos y EBSCO Host tuvo 2 publicaciones.

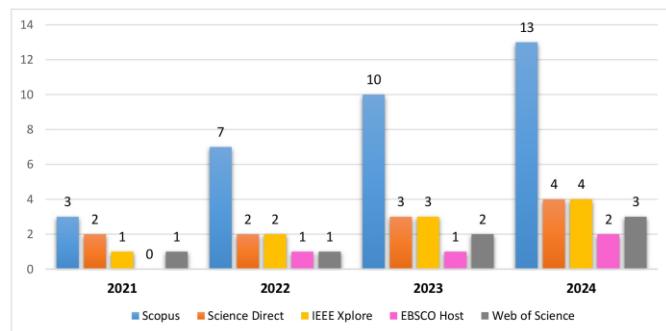


Fig. 6 Artículos por año y base de datos

La Figura 7 muestra la distribución de artículos publicados según el país, resaltando a China como el principal contribuyente a la investigación con un total de 19 artículos. En segundo lugar se encuentra China con 14 artículos, lo que refleja su dedicación a la generación de conocimiento científico. Estados Unidos sigue con 5 artículos, evidenciando también su compromiso con la investigación. Egipto, Arabia Saudita, Malasia, Australia y Taiwán han contribuido con 3 artículos cada uno. Corea del Sur, Serbia e Irlanda han registrado 2 publicaciones cada uno. Finalmente, los países que menos han publicado son Francia, Alemania, España, Canadá, Inglaterra y Japón, cada uno con un solo artículo.

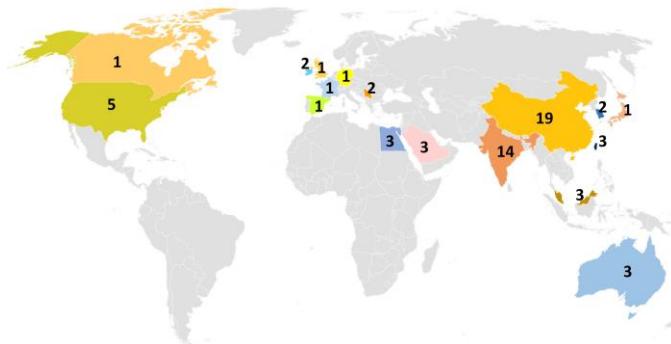


Fig. 7 Número de artículos publicados por país

## V. DISCUSIÓN

Se llevó a cabo un riguroso proceso de selección de literatura para identificar estudios que utilizan técnicas de Machine Learning y Deep Learning en el análisis de la calidad del agua, lo que permitió detectar tendencias y vacíos en la investigación y responder a las preguntas del estudio. El objetivo es mejorar el monitoreo y análisis de la calidad del agua mediante estas tecnologías avanzadas.

RQ1: ¿Cuáles son las diferencias fundamentales entre las características de Machine Learning y Deep Learning en el análisis de la calidad del agua?

La Tabla 2 resume las principales diferencias entre Machine Learning y Deep Learning. En Machine Learning, se necesita un menor volumen de datos [19] y se pueden utilizar

menos recursos computacionales. En contraste, Deep Learning requiere grandes volúmenes de datos [48], lo cual es fundamental para llevar a cabo tareas como la predicción de la contaminación del agua. Esta distinción resalta no solo las ventajas de Machine Learning en escenarios donde los datos son limitados, sino también el potencial de Deep Learning para desarrollar modelos más complejos y precisos en contextos con abundancia de datos. Por lo tanto, la selección entre Machine Learning y Deep Learning debe considerar tanto la disponibilidad de datos como los objetivos específicos del análisis.

TABLA II  
DIFERENCIAS ENTRE MACHINE LEARNING Y DEEP LEARNING

Campos de la IA	Características	Referencia
Machine Learning	Requiere menos Datos	[19], [21], [22], [23], [24], [25], [26], [27], [28], [29], [30], [31], [32], [33], [34], [35].
	Menos recursos Computacionales	[19], [21], [23], [24], [29], [31], [32], [34], [36], [37], [38].
	Intervención humana	[39], [25], [29], [30], [31].
	Entrenamiento más Rápida	[23], [29], [30], [31], [36], [39], [40], [41].
	Correlaciones simples y lineales	[29], [42], [43], [44], [45].
	Predicción	[23], [27], [34], [36], [37], [42], [46], [47], [35].
Deep Learning	Grandes cantidades de datos	[18], [48], [49], [50], [51], [52], [53], [54], [55], [56], [57], [58], [59], [60], [61], [62], [63], [64], [65], [66], [67], [68], [69].
	Utiliza más recursos computacionales	[18], [38], [49], [50], [53], [54], [56], [57], [58], [60], [62], [63], [64], [66], [70].
	Aprende por sí mismo	[18], [36], [49], [52], [57], [62], [63], [64], [71].
	Mayor Entrenamiento	[50], [54], [56], [60], [72], [70].
	Correlaciones no lineales y complejas	[49], [50], [51], [54], [57], [58], [60], [62], [70], [72], [73].
	Con imágenes	[34], [38], [56], [61], [65], [74].
	Predicción	[18], [48], [49], [50], [51], [52], [53], [54], [56], [58], [60], [61], [62], [63], [64], [66], [67], [69], [70], [71].

RQ2: ¿Cuáles son los algoritmos más utilizados de Machine Learning y Deep Learning para analizar la calidad del agua?

La elección del algoritmo adecuado para el análisis de la calidad del agua depende de los resultados deseados. En Machine Learning, el Bosque Aleatorio es popular por su eficacia en gestionar datos complejos y ruidosos. Le sigue el Support Vector Machine (SVM), debido a su flexibilidad y resistencia al sobreajuste. En Deep Learning, el modelo más utilizado es el Long Short-Term Memory (LSTM), que

permite comprender los factores que influyen en los ecosistemas acuáticos y tomar decisiones informadas sobre la gestión del agua. Seguido de las Redes Neuronales Convolucionales (CNN), que identifican patrones en datos complejos y gestionar grandes volúmenes de información. En consecuencia, La elección del algoritmo para analizar la calidad del agua es crucial. El Bosque Aleatorio es eficaz con datos complejos, mientras que SVM es flexible y resistente al sobreajuste. En Deep Learning, las LSTM son útiles para el análisis del agua y las CNN identifican patrones en grandes volúmenes de datos. La elección del algoritmo debe basarse en las características de los datos y los objetivos del análisis para asegurar un procesamiento efectivo de la calidad del agua.

TABLA III  
TIPO DE ALGORITMOS DE MACHINE LEARNING Y DEEP LEARNING

Campos de la IA	Algoritmos	Referencia
Machine Learning	Regresión Lineal	[19], [24], [40], [41], [42], [43], [45], [48].
	Árboles de decisión	[19], [23], [24], [29], [32], [37], [39], [40], [41], [42], [47], [35].
	SVM	[19], [23], [24], [25], [26], [27], [29], [31], [33], [34], [37], [38], [39], [40], [41], [42], [48], [56], [61], [66], [75].
	Bosque aleatorio (RF)	[36], [23], [37], [39], [25], [42], [43], [26], [75], [45], [47], [27], [40], [74], [41], [61], [29], [66], [31], [32], [34], [35].
	ANN	[23], [24], [25], [36], [39], [42], [48], [52], [59], [75].
	KNN	[18], [19], [29], [37], [36], [38], [41], [44], [47].
	Bayesianas ingenuo	[19], [37], [47], [41], [66].
Deep Learning	XGBoost	[18], [22], [28], [29], [32], [36], [38], [40], [61], [67], [74], [35].
	CNN	[33], [38], [49], [50], [52], [65], [68], [70], [72], [73].
	RNN	[38], [48], [49], [50], [51], [56], [66].
	LSTM	[22], [30], [46], [48], [50], [51], [52], [57], [59], [60], [62], [66], [67], [68], [70], [71].
	DNN	[33], [38], [53], [55], [61], [72].
	BiLSTM	[28], [56], [63], [69].
	Backpropagation	[40], [46], [54], [58].
	Híbrido CNN-LSTM	[18], [54], [64], [70].

RQ3: ¿Cuáles son las principales limitaciones de las técnicas de Machine Learning y Deep Learning en el análisis de la calidad del agua en sistemas basados en IoT?

La Tabla 4 ofrece un análisis de diversos artículos que examinan las limitaciones del Machine Learning y el Deep Learning en la evaluación de la calidad del agua. Estos estudios destacan que el rendimiento del Machine Learning está intrínsecamente ligado a la calidad de los datos [22], y hacen hincapié en el uso del error cuadrático medio como

medida estadística para evaluar la precisión entre los valores observados y los predichos en el contexto de la calidad del agua. Por otro lado, las restricciones relacionadas con el Deep Learning se centran no solo en su dependencia de la calidad de los datos [46], sino también en los requerimientos computacionales que demanda. Las limitaciones del machine learning resaltan la importancia de tener datos de alta calidad y de evaluar la precisión de los modelos mediante el error cuadrático medio, especialmente en estudios de calidad del agua. El deep learning, además de requerir datos de calidad, necesita recursos computacionales significativos, lo que afecta la efectividad de los análisis. En resumen, la efectividad de ambas técnicas para evaluar el agua depende no solo de los algoritmos, sino también de la calidad de los datos y de la infraestructura computacional.

TABLA IV  
LIMITACIONES DE MACHINE LEARNING Y DEEP LEARNING

Campos de la IA	Limitaciones	Referencia
Machine Learning	Depende de la calidad de los datos.	[22], [27], [29], [30], [31], [32], [33], [34], [46], [44], [75], [76].
	Interpretabilidad	[23], [29], [46], [44], [75].
	Datos con ruido	[30], [38], [41], [45], [46], [75], [76].
	Variabilidad ambiental	[23], [40], [46], [75].
	Requisitos computacionales	[22], [34], [47], [75].
	Error cuadrático medio	[29], [30], [32], [41], [45], [52], [59], [35], [76].
Deep Learning	Depende de la calidad de los datos	[18], [28], [46], [48], [49], [50], [52], [53], [55], [56], [57], [59], [60], [61], [62], [63], [64], [65], [66], [68], [69], [71], [74].
	Difícil interpretar resultados	[46], [56], [57], [58], [62], [71].
	Datos con ruido	[30], [38], [55], [60].
	Tiempo de cálculo	[50], [51], [57], [58], [60], [61], [70], [71].
	Requerimientos computacionales	[48], [49], [50], [51], [56], [60], [62], [63], [66].
	Costo	[52], [60], [61], [62], [65], [66].
	Mayor entrenamiento	[49], [56], [57], [58], [68], [70], [71], [72].

RQ4: ¿Cómo la integración de técnicas de Machine Learning y Deep Learning contribuye a mejorar el análisis de la calidad del agua?

La Tabla 5 muestra una integración de técnicas de Machine Learning y Deep Learning que han demostrado ser fundamentales para optimizar el análisis de la calidad del agua. Se llevaron a cabo diversas pruebas y se evaluaron múltiples métodos dentro de estas tecnologías, cada uno de los cuales evidenció mejoras en eficiencia y precisión en comparación con otros enfoques. Entre ellos, los métodos más

destacados fueron la combinación de XGBoost y GRU (Gated Recurrent Unit), obteniéndose un 99% de precisión. Los Métodos como XGBoost y GRU son efectivos en la predicción y clasificación de datos, lo que beneficia la gestión de recursos hídricos. La combinación de estas técnicas puede generar sinergias útiles. Esta integración tecnológica puede transformar el monitoreo de la calidad del agua, ofreciendo soluciones más efectivas y sostenibles para la gestión de recursos hídricos.

TABLA V  
LA INTEGRACIÓN DE TÉCNICAS DE MACHINE LEARNING Y DEEP LEARNING

Métodos		Método más eficiente	Precisión %	Referencia
Machine Learning	Deep Learning			
Boruta-XGBoost, KNN	CNN-LSTM, MLP	Boruta-XGB-CNN-LSTM	0,9429	[18]
RFR, SVR, AdaBoost, XGBoost	BiLSTM, GRU	XGBoost y GRU	0.99	[28]
	Regresión Lineal, SVM, ANN	RNN, LSTM, Hybrid CNN – ELM	0.920	[48]
	SVR, GRP, ANN.	LSTM, CNN, ConvLSTM,	0.899	[52]
	Regresión Lineal múltiple (MLR), SVR y regresión forestal aleatoria.	DNN	DNN	0.889 [53]
	SVM, MLP	LSTM, BiLSTM., RNN	BiLSTM-SVM	0.98 [56]
	Bosque aleatorio, SVM, XGBoost	DNN, SDD-DNN	DNN	0.91 [61]
	Bosque aleatorio, Bayesianas ingenuo SVM,	ANN, RNN,LSTM	RNN y LSTM	0.89 [66]
	XGBoost	LSTM, MixUp-LSTM	MixUp-LSTM	0,9208 [67]
	Bosque aleatorio, XGBoost, GBR	MDN, Transformer	XGBoost	0.82 [74]

## VI. CONCLUSIONES

La elección entre Machine Learning y Deep Learning depende de la cantidad de datos y los objetivos del análisis: Machine Learning es más adecuado para datos limitados y recursos reducidos, mientras que Deep Learning es ideal para grandes volúmenes de datos y modelos complejos. Esta comprensión ayuda a optimizar el uso de ambas técnicas según las necesidades del proyecto.

La elección del algoritmo adecuado para analizar la calidad del agua es fundamental y debe alinearse con las características de los datos. Algoritmos como Bosque Aleatorio y Support Vector Machine son efectivos para datos complejos, mientras que los modelos LSTM y CNN en Deep

Learning son esenciales para entender dinámicas ecológicas y detectar patrones en grandes volúmenes de información. Una selección cuidadosa mejora el procesamiento de datos y la gestión del agua, promoviendo la sostenibilidad de los ecosistemas acuáticos.

El análisis revela que el Machine Learning y el Deep Learning tienen limitaciones significativas en la evaluación de la calidad del agua, vinculadas a la calidad de los datos y los recursos computacionales necesarios en el caso del Deep Learning. Ambos enfoques requieren atención a la calidad de los datos y la precisión de las mediciones, subrayando que su efectividad depende de los algoritmos y de la infraestructura de soporte. Estos hallazgos destacan la importancia de abordar estas limitaciones para optimizar el uso de estas tecnologías en estudios ambientales.

La combinación de XGBoost y GRU en Machine Learning y Deep Learning ha logrado una precisión del 99% en el análisis de la calidad del agua, mejorando la eficiencia del monitoreo ambiental y facilitando una gestión sostenible de los recursos hídricos. Esto transforma las prácticas de monitoreo y ofrece soluciones efectivas para la protección del agua.

## REFERENCIAS

- [1] B. L. Keeler *et al.*, “Linking water quality and well-being for improved assessment and valuation of ecosystem services,” *Proc. Natl. Acad. Sci.*, vol. 109, no. 45, pp. 18619–18624, Nov. 2012, doi: 10.1073/PNAS.1215991109.
- [2] P. (Dr. . P. S. Kamble and M. A. C. Kamble, “HEALTH EFFECTS OF WATER POLLUTION,” *EPRA Int. J. Econ. Bus. Rev.*, pp. 45–50, Sep. 2022, doi: 10.36713/EPRA11200.
- [3] N. Semeniuk, “ECOLOGICAL WATER QUALITY,” *Ukr. J. Nat. Sci.*, no. 2, pp. 45–56, Jan. 2023, doi: 10.35433/NATURALJOURNAL.2.2023.45-56.
- [4] R. P. Schwarzenbach *et al.*, “The Challenge of Micropollutants in Aquatic Systems,” *Science* (80- .), vol. 313, no. 5790, pp. 1072–1077, Aug. 2006, doi: 10.1126/SCIENCE.1127291.
- [5] H. Kolya and C. W. Kang, “Toxicity of Metal Oxides, Dyes, and Dissolved Organic Matter in Water: Implications for the Environment and Human Health,” *Toxics*, vol. 12, no. 2, Feb. 2024, doi: 10.3390/TOXICS12020111.
- [6] L. Lin, H. Yang, and X. Xu, “Effects of Water Pollution on Human Health and Disease Heterogeneity: A Review,” *Front. Environ. Sci.*, vol. 10, Jun. 2022, doi: 10.3389/FENVS.2022.880246/PDF.
- [7] Q. Yasmeen and S. Yasmeen, “Impact of Drinking Water on People’s Health and Water Borne Diseases,” *Pakistan Biomed. J.*, pp. 31–35, Jul. 2023, doi: 10.54393/PBMJ.V6I07.867.
- [8] N. J. Ashbolt, “Microbial contamination of drinking water and disease outcomes in developing regions,” *Toxicology*, vol. 198, no. 1–3, pp. 229–238, May 2004, doi: 10.1016/J.TOX.2004.01.030.
- [9] E. El-Shafeiy, M. Alsabaan, M. I. Ibrahim, and H. Elwahsh, “Real-Time Anomaly Detection for Water Quality Sensor Monitoring Based on Multivariate Deep Learning Technique,” *Sensors (Basel.)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/S23208613.
- [10] A. E. Alprol, A. T. Mansour, M. E. E.-D. Ibrahim, and M. Ashour, “Artificial Intelligence Technologies Revolutionizing Wastewater Treatment: Current Trends and Future Prospective,” *Water (Switzerland)*, vol. 16, no. 2, 2024, doi: 10.3390/w16020314.
- [11] G. Mostafa, H. Mahmoud, T. Abd El-Hafeez, and M. E. ElAraby, “Feature reduction for hepatocellular carcinoma prediction using machine learning algorithms,” *J. Big Data*, vol. 11, no. 1, Dec. 2024, doi: 10.1186/S40537-024-00944-3.
- [12] A. M. Elsayad *et al.*, “Machine learning model for random forest acute oral toxicity prediction,” *Glob. J. Environ. Sci. Manag.*, vol. 11, no. 1, pp. 21–38, Dec. 2025, doi: 10.22034/GJESM.2025.01.02.
- [13] L. Abualigah, Y. Y. Al-Ajlouni, M. S. Daoud, M. Altalhi, and H. Migdady, “Fake news detection using recurrent neural network based on bidirectional LSTM and GloVe,” *Soc. Netw. Anal. Min.*, vol. 14, no. 1, Dec. 2024, doi: 10.1007/S13278-024-01198-W.
- [14] Y. Li, “Analysis of English Classroom Teaching Behavior Mode in Environmental Protection Field Based on Deep Learning,” *Int. J. Comput. Intell. Syst.*, vol. 17, no. 1, Dec. 2024, doi: 10.1007/S44196-024-00457-0.
- [15] S. Z. Farzana, D. R. Paudyal, S. Chadalavada, and M. J. Alam, “Temporal Dynamics and Predictive Modelling of Streamflow and Water Quality Using Advanced Statistical and Ensemble Machine Learning Techniques,” *Water (Switzerland)*, vol. 16, no. 15, Aug. 2024, doi: 10.3390/W16152107.
- [16] A. Kumar Lall, A. Terala, A. Goyal, S. Chaudhari, K. S. Rajan, and S. S. Chouhan, “Behavioural Analysis of Water Consumption using IoT-based Smart Retrofit Meter,” *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3436889.
- [17] B. Perumal, N. Rajarethinam, A. D. Velusamy, and V. P. Sundramurthy, “Water Quality Prediction Based on Hybrid Deep Learning Algorithm,” *Adv. Civ. Eng.*, vol. 2023, 2023, doi: 10.1155/2023/6644681.
- [18] M. Karbasi *et al.*, “Multi-step ahead forecasting of electrical conductivity in rivers by using a hybrid Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM) model enhanced by Boruta-XGBoost feature selection algorithm,” *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/S41598-024-65837-0.
- [19] X. Xu, T. Lai, S. Jahan, F. Farid, and A. Bello, “A Machine Learning Predictive Model to Detect Water Quality and Pollution,” *Futur. Internet*, vol. 14, no. 11, Nov. 2022, doi: 10.3390/FI14110324.
- [20] Z. Zhang, S. Zhang, C. Chen, and J. Yuan, “A systematic survey of air quality prediction based on deep learning,” *Alexandria Eng. J.*, vol. 93, pp. 128–141, 2024, doi: <https://doi.org/10.1016/j.aej.2024.03.031>.
- [21] N. A. Suwadi *et al.*, “An Optimized Approach for Predicting Water Quality Features Based on Machine Learning,” *Wirel. Commun. Mob. Comput.*, vol. 2022, 2022, doi: 10.1155/2022/3397972.
- [22] M. N. Adli Zakaria *et al.*, “Exploring machine learning algorithms for accurate water level forecasting in Muda river, Malaysia,” *Helijon*, vol. 9, no. 7, p. e17689, Jul. 2023, doi: 10.1016/J.HELJON.2023.E17689.
- [23] R. Huang, C. Ma, J. Ma, X. Huangfu, and Q. He, “Machine learning in natural and engineered water systems,” *Water Res.*, vol. 205, p. 117666, Oct. 2021, doi: 10.1016/J.WATRES.2021.117666.
- [24] A. M. Sajib *et al.*, “Assessing water quality of an ecologically critical urban canal incorporating machine learning approaches,” *Ecol. Inform.*,

- vol. 80, May 2024, doi: 10.1016/J.ECOINF.2024.102514.
- [25] M. Lowe, R. Qin, and X. Mao, "A Review on Machine Learning, Artificial Intelligence, and Smart Technology in Water Treatment and Monitoring," *Water (Switzerland)*, vol. 14, no. 9, May 2022, doi: 10.3390/W14091384.
- [26] X. Li, J. Ding, and N. Ilyas, "Machine learning method for quick identification of water quality index (WQI) based on Sentinel-2 MSI data: Ebinur Lake case study," *Water Sci. Technol. Water Supply*, vol. 21, no. 3, pp. 1291 – 1312, 2021, doi: 10.2166/ws.2020.381.
- [27] M. Mori, R. Gonzalez Flores, Y. Suzuki, K. Nukazawa, T. Hiraoka, and H. Nonaka, "Prediction of Microcysts Occurrences and Analysis Using Machine Learning in High-Dimension, Low-Sample-Size and Imbalanced Water Quality Data," *Harmful Algae*, vol. 117, Aug. 2022, doi: 10.1016/J.HAL.2022.102273.
- [28] S. Z. Farzana, D. R. Paudyal, S. Chadalavada, and M. J. Alam, "Prediction of Water Quality in Reservoirs: A Comparative Assessment of Machine Learning and Deep Learning Approaches in the Case of Toowoomba, Queensland, Australia," *Geosci.*, vol. 13, no. 10, Oct. 2023, doi: 10.3390/GEOSCIENCES13100293.
- [29] V. Sangwan and R. Bhardwaj, "Machine learning framework for predicting water quality classification," *Water Pract. Technol.*, vol. 19, no. 11, pp. 4499–4521, Nov. 2024, doi: 10.2166/WPT.2024.259.
- [30] S. Huang, J. Xia, Y. Wang, J. Lei, and G. Wang, "Water quality prediction based on sparse dataset using enhanced machine learning," *Environ. Sci. Ecotechnology*, vol. 20, Jul. 2024, doi: 10.1016/J.ESE.2024.100402.
- [31] S. Karasaki, R. Morello-Frosch, and D. Callaway, "Machine learning for environmental justice: Dissecting an algorithmic approach to predict drinking water quality in California," *Sci. Total Environ.*, vol. 951, 2024, doi: 10.1016/j.scitotenv.2024.175730.
- [32] H. Zheng, S. Hou, J. Liu, Y. Xiong, and Y. Wang, "Advanced Machine Learning and Water Quality Index (WQI) Assessment: Evaluating Groundwater Quality at the Yopurga Landfill," *Water (Switzerland)*, vol. 16, no. 12, Jun. 2024, doi: 10.3390/W16121666.
- [33] P. Gupta, P. Samui, and A. R. Quaff, "Estimation of water quality index using modern-day machine learning algorithms," *Sadhana - Acad. Proc. Eng. Sci.*, vol. 49, no. 3, Sep. 2024, doi: 10.1007/S12046-024-02545-5.
- [34] V. Anand, B. Oinam, and S. Wiprecht, "Machine learning approach for water quality predictions based on multispectral satellite imageries," *Ecol. Inform.*, vol. 84, Dec. 2024, doi: 10.1016/J.ECOINF.2024.102868.
- [35] N. K. Tiwari and D. Panwar, "Optimising Venturi flume oxygen transfer efficiency using uncertainty-aware decision trees," *Water Sci. Technol.*, vol. 90, no. 12, pp. 3210–3240, Dec. 2024, doi: 10.2166/WST.2024.393.
- [36] S. Singha, S. Pasupuleti, S. S. Singha, R. Singh, and S. Kumar, "Prediction of groundwater quality using efficient machine learning technique," *Chemosphere*, vol. 276, p. 130265, Aug. 2021, doi: 10.1016/J.CHEMOSPHERE.2021.130265.
- [37] K. Abirami, P. C. Radhakrishna, and M. A. Venkatesan, "Water Quality Analysis and Prediction using Machine Learning," *Proc. - 2023 12th IEEE Int. Conf. Commun. Syst. Netw. Technol. CSNT 2023*, pp. 241–245, 2023, doi: 10.1109/CSNT57126.2023.10134661.
- [38] S. S. Mukonza and J. L. Chiang, "Meta-Analysis of Satellite Observations for United Nations Sustainable Development Goals: Exploring the Potential of Machine Learning for Water Quality Monitoring," *Environ. - MDPI*, vol. 10, no. 10, Oct. 2023, doi: 10.3390/ENVIRONMENTS10100170.
- [39] S. Cojbasic *et al.*, "Application of machine learning in river water quality management: a review," *Water Sci. Technol.*, vol. 88, no. 9, pp. 2297 – 2308, 2023, doi: 10.2166/wst.2023.331.
- [40] N. Nasir *et al.*, "Water quality classification using machine learning algorithms," *J. Water Process Eng.*, vol. 48, p. 102920, Aug. 2022, doi: 10.1016/J.JWPE.2022.102920.
- [41] P. Rawat, M. Bajaj, V. Sharma, and S. Vats, "A Comprehensive Analysis of the Effectiveness of Machine Learning Algorithms for Predicting Water Quality," *Int. Conf. Innov. Data Commun. Technol. Appl. ICIDCA 2023 - Proc.*, pp. 1108–1114, 2023, doi: 10.1109/ICIDCA56705.2023.10099968.
- [42] J. Mohd Zebaral Hoque, N. A. Nor, S. Alelyani, M. Mohana, and M. Hosain, "Improving Water Quality Index Prediction Using Regression Learning Models," *Int. J. Environ. Res. Public Health*, vol. 19, no. 20, Oct. 2022, doi: 10.3390/IJERPH192013702.
- [43] M. Kovačević, B. Jabbarian Amiri, S. Lozančić, M. Hadzima-Nyarko, D. Radu, and E. K. Nyarko, "Application of Machine Learning in Modeling the Relationship between Catchment Attributes and Instream Water Quality in Data-Scarce Regions," *Toxics*, vol. 11, no. 12, p. 996, Dec. 2023, doi: 10.3390/toxics11120996.
- [44] S. Kolli, M. Ranjani, P. Kavitha, D. A. P. Daniel, and A. Chandramauli, "Prediction of water quality parameters by IoT and machine learning," *2023 Int. Conf. Comput. Commun. Informatics, ICCCI 2023*, 2023, doi: 10.1109/ICCCI56745.2023.10128475.
- [45] C. Cheng *et al.*, "Urban Fine-Grained Water Quality Monitoring Based on Stacked Machine Learning Approach," *IEEE Access*, vol. 12, pp. 77156–77170, 2024, doi: 10.1109/ACCESS.2024.3404068.
- [46] J. Zhou, J. Wang, Y. Chen, X. Li, and Y. Xie, "Water quality prediction method based on multi-source transfer learning for water environmental IoT system," *Sensors*, vol. 21, no. 21, Nov. 2021, doi: 10.3390/S21217271.
- [47] M. G. Uddin, S. Nash, M. T. Mohammad Diganta, A. Rahman, and A. I. Olbert, "Robust machine learning algorithms for predicting coastal water quality index," *J. Environ. Manage.*, vol. 321, 2022, doi: 10.1016/j.jenvman.2022.115923.
- [48] S. V. Jansi Rani, A. M. Ramakrishnan, and K. Rishivardhan, "Improving water quality assessment through anomaly detection using hybrid convolutional neural network approach," *Glob. Nest J.*, vol. 24, no. 1, pp. 1–8, Mar. 2022, doi: 10.30955/GNJ.003923.
- [49] A. F. Gambin, E. Angelats, J. S. Gonzalez, M. Miozzo, and P. Dlni, "Sustainable Marine Ecosystems: Deep Learning for Water Quality Assessment and Forecasting," *IEEE Access*, vol. 9, pp. 121344–121365, 2021, doi: 10.1109/ACCESS.2021.3109216.
- [50] H. Choi, S. I. Suh, S. H. Kim, E. J. Han, and S. J. Ki, "Assessing the performance of deep learning algorithms for short-term surface water quality prediction," *Sustain.*, vol. 13, no. 19, Oct. 2021, doi: 10.3390/SU131910690.
- [51] Y. Jiang, C. Li, L. Sun, D. Guo, Y. Zhang, and W. Wang, "A deep learning algorithm for multi-source data fusion to predict water quality of urban sewer networks," *J. Clean. Prod.*, vol. 318, Oct. 2021, doi:

- 10.1016/J.JCLEPRO.2021.128533.
- [52] S. S. Mukonza and J.-L. Chiang, "Micro-Climate Computed Machine and Deep Learning Models for Prediction of Surface Water Temperature Using Satellite Data in Mundan Water Reservoir," *Water (Switzerland)*, vol. 14, no. 18, 2022, doi: 10.3390/w14182935.
- [53] J. Qian *et al.*, "Water quality monitoring and assessment based on cruise monitoring, remote sensing, and deep learning: A case study of Qingcaosha Reservoir," *Front. Environ. Sci.*, vol. 10, Oct. 2022, doi: 10.3389/FENVS.2022.979133.
- [54] H. Wu *et al.*, "Water Quality Prediction Based on Multi-Task Learning," *Int. J. Environ. Res. Public Health*, vol. 19, no. 15, 2022, doi: 10.3390/ijerph19159699.
- [55] S. Chopade, H. P. Gupta, R. Mishra, A. Oswal, P. Kumari, and T. Dutta, "A Sensors-Based River Water Quality Assessment System Using Deep Neural Network," *IEEE Internet Things J.*, vol. 9, no. 16, pp. 14375–14384, Aug. 2022, doi: 10.1109/JIOT.2021.3078892.
- [56] Z. Jamshidzadeh, M. Ehteram, and H. Shabani, "Bidirectional Long Short-Term Memory (BiLSTM) - Support Vector Machine: A new machine learning model for predicting water quality parameters," *Ain Shams Eng. J.*, vol. 15, no. 3, Mar. 2024, doi: 10.1016/J.ASEJ.2023.102510.
- [57] I. Janbain, A. Jardani, J. Deloffre, and N. Massei, "Deep Learning Approaches for Numerical Modeling and Historical Reconstruction of Water Quality Parameters in Lower Seine," *Water (Switzerland)*, vol. 15, no. 9, May 2023, doi: 10.3390/W15091773.
- [58] H. Zheng, Y. Liu, W. Wan, J. Zhao, and G. Xie, "Large-scale prediction of stream water quality using an interpretable deep learning approach," *J. Environ. Manage.*, vol. 331, Apr. 2023, doi: 10.1016/J.JENVMAN.2023.117309.
- [59] R. Rana *et al.*, "Artificial Intelligence for Surface Water Quality Evaluation, Monitoring and Assessment," *Water (Switzerland)*, vol. 15, no. 22, Nov. 2023, doi: 10.3390/W15223919.
- [60] J. Dong, Z. Wang, J. Wu, J. Huang, and C. Zhang, "A water quality prediction model based on signal decomposition and ensemble deep learning techniques," *Water Sci. Technol.*, vol. 88, no. 10, pp. 2611–2632, Nov. 2023, doi: 10.2166/WST.2023.357.
- [61] A. Ali, G. Zhou, F. Pablo Antezana Lopez, C. Xu, G. Jing, and Y. Tan, "Deep learning for water quality multivariate assessment in inland water across China," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 133, p. 104078, Sep. 2024, doi: 10.1016/J.JAG.2024.104078.
- [62] Y. Kim, S. Kwak, M. Lee, M. Jeong, M. Park, and Y.-G. Park, "Determination of Optimal Water Intake Layer Using Deep Learning-Based Water Quality Monitoring and Prediction," *Water (Switzerland)*, vol. 16, no. 1, 2024, doi: 10.3390/w16010015.
- [63] W. F. Alfwzan, M. M. Selim, A. S. Almalki, and I. S. Alharbi, "Water quality assessment using Bi-LSTM and computational fluid dynamics (CFD) techniques," *Alexandria Eng. J.*, vol. 97, pp. 346–359, Jun. 2024, doi: 10.1016/J.AEJ.2024.04.030.
- [64] S. Yang, S. Zhong, and K. Chen, "W-WaveNet: A multi-site water quality prediction model incorporating adaptive graph convolution and CNN-LSTM," *PLoS One*, vol. 19, no. 3 March, Mar. 2024, doi: 10.1371/JOURNAL.PONE.0276155.
- [65] Y. Zuo, G. Li, W. Ren, and Y. Hu, "A Deep Similarity Clustering Network With Compound Regularization for Unsupervised PolSAR Image Classification," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 17, pp. 11451–11466, 2024, doi: 10.1109/JSTARS.2024.3400847.
- [66] R. Amireddy and P. Dileep, "A Comparative Study on Water Quality Prediction Using Machine Learning and Deep Learning Techniques," in *3rd IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics, ICDCECE 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICDCECE60827.2024.10548555.
- [67] X. Liang *et al.*, "Dissolved Oxygen Concentration Prediction in the Pearl River Estuary with Deep Learning for Driving Factors Identification: Temperature, pH, Conductivity, and Ammonia Nitrogen," *Water (Switzerland)*, vol. 16, no. 21, Nov. 2024, doi: 10.3390/W16213090.
- [68] A. J. De La Noval, H. Upadhyay, L. Lagos, J. Soni, and N. Prabakar, "Spatial-temporal analysis of groundwater well features from neural network prediction of hexavalent chromium concentration," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/S41598-024-82297-8.
- [69] X. Yang, J. Li, and X. Jiang, "Research on information leakage in time series prediction based on empirical mode decomposition," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/S41598-024-80018-9.
- [70] K. P. Rasheed Abdul Haq and V. P. Harigovindan, "Water Quality Prediction for Smart Aquaculture Using Hybrid Deep Learning Models," *IEEE Access*, vol. 10, pp. 60078–60098, 2022, doi: 10.1109/ACCESS.2022.3180482.
- [71] V. M. Sathya Preiya, P. Subramanian, M. Soniya, and R. Pugalethi, "Water quality index prediction and classification using hyperparameter tuned deep learning approach," *Glob. Nest J.*, vol. 26, no. 5, p. 05821, Jan. 2024, doi: 10.30955/GNJ.005821.
- [72] "Coupling Machine and Deep Learning with Explainable Artificial Intelligence for Improving Prediction of Groundwater Quality and Decision-Making in Arid Region, Saudi Arabia." Accessed: Aug. 30, 2024. [Online]. Available: <https://web.p.ebscohost.com/abstract?site=ehost&scope=site&jrnln=20734441&AN=164684517&h=v9oo59deXgOzGhnN0aroKyaceTm5nu2Ykr2sbQTmnc6rh%2FK9wo24OeJut17Py9TP3gyjydlFC3v8%2Fx6jItOnUw%3D%3D&crl=c&resultLocal=ErrCrlNoResults&resultNs=Eho st&crlhashurl=login.aspx>
- [73] H. Zhang, B. Xue, G. Wang, X. Zhang, and Q. Zhang, "Deep Learning-Based Water Quality Retrieval in an Impounded Lake Using Landsat 8 Imagery: An Application in Dongping Lake," *Remote Sens.*, vol. 14, no. 18, Sep. 2022, doi: 10.3390/RS14184505.
- [74] W. Yang *et al.*, "Monitoring multi-water quality of internationally important karst wetland through deep learning, multi-sensor and multi-platform remote sensing images: A case study of Guilin, China," *Ecol. Indic.*, vol. 154, 2023, doi: 10.1016/j.ecolind.2023.110755.
- [75] Y. Kumar and S. K. Udgata, "Machine learning model for IoT-Edge device based Water Quality Monitoring," in *INFOCOM WKSHPS 2022 - IEEE Conference on Computer Communications Workshops*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/INFOCOMWKSHPS54753.2022.9798212.
- [76] Y. Zhou *et al.*, "Spatial-temporal distribution of labeled set bias remote sensing estimation: An implication for supervised machine learning in water quality monitoring," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 131, Jul. 2024, doi: 10.1016/J.JAG.2024.103959.