



Revista Micaela

ISSN: 2955-8646 (en línea) / 2709-8990 (Impresa)
Universidad Nacional Micaela Bastidas de Apurímac
Vice Rectorado de Investigación – Perú

Vol. 6 Num. 1 (2025) - Publicado: 01/10/25
<https://doi.org/10.57166/micaela.v6.n1.2025>
Páginas: 1- 7
Recibido 23/12/2025 ; Aceptado 30/12/2024

<https://doi.org/10.57166/micaela.v6.n1.2025.169>

Edición Especial: FERCYT UNAMBA - 2024

Autores:

1. **ORCID iD** <https://orcid.org/0009-0004-9354-5137>
Royer Elvis Moreano-Condorcuya, estudiante de la Escuela Académica Profesional Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac
2. **ORCID iD** <https://orcid.org/0009-0005-5374> Aron Omar Pizarro-Cahuana, estudiante de la Escuela Académica Profesional Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac
3. **ORCID iD** <https://orcid.org/0000-0002-3058-9683>
Erech Ordoñez-Ramos, docente del Departamento de Ingeniería Informática y Sistemas de la Universidad Micaela Bastidas de Apurímac, eordonhez@unamba.edu.pe
4. **ORCID iD** <https://orcid.org/0000-0002-0258-8632>
Alejandrina Huaylla-Quispe, docente del Departamento de Ingeniería Informática y Sistemas de la Universidad Micaela Bastidas de Apurímac, ahuaylla@unamba.edu.pe

Aplicación de Aprendizaje Automático para la Predicción de la Calidad del Agua Potable en la Universidad Nacional Micaela Bastidas de Apurímac

Machine Learning Application for the Prediction of Drinking Water Quality at the Micaela Bastidas National University of Apurímac

Royer Elvis Moreano-Condorcuya¹, Aron Omar Pizarro-Cahuana², Erech Ordoñez-Ramos³ y Alejandrina Huaylla-Quispe⁴

Resumen. El presente proyecto de investigación se transcribió para presentar al concurso de Feria de Ciencia y Tecnología FERCYT del 2024, en la categoría de póster científico, organizado por la Universidad Micaela Bastidas de Apurímac, el proyecto de investigación tiene por objetivo evaluar la calidad del agua potable que llega a la Universidad Nacional Micaela Bastidas de Apurímac (UNAMBA) para ello se usara modelos de aprendizaje predictivo como lo son Redes Neuronales (RN) y Sistemas Neuro-Difusos Adaptativos (ANFIS). Los datos se recopilarán en la universidad, se analizarán con los indicadores de la calidad del agua. Los modelos se corroboran mediante el uso de las métricas como RMSE que es el error cuadrático medio, MAE que es el error absoluto medio, y R^2 que es el coeficiente de determinación, las pruebas estadísticas que se usaran son T student para evaluar diferencias significativas en los parámetros de calidad antes y después del ajuste de modelos predictivos y ANOVA para comparar los desempeños de RN y ANFIS en diferentes parámetros de calidad del agua. Se espera que los resultados permitan implementar sistemas de monitoreo en tiempo real, contribuyendo a la mejora de la calidad del agua en la institución [1] -[2]

Palabras clave: Aprendizaje automático, calidad del agua, predicción, redes neuronales, ANFIS.

Abstract. This research project was transcribed to present to the FERCYT Science and Technology Fair contest of 2024, in the scientific poster category, organized by the Micaela Bastidas University of Apurímac, the research project aims to evaluate the quality of drinking water that arrives at the Micaela Bastidas de Apurímac National University (UNAMBA) for this purpose, predictive learning models such as Neural Networks (RN) and Systems will be used. Adaptive Neuro-Diffuse (ANFIS). Data will be collected at the university, analyzed with water quality indicators. The models are corroborated by using metrics such as RMSE, which is the mean square error, MAE, which is the mean absolute error, and R^2 , which is the coefficient of determination. The statistical tests that will be used are T student to evaluate significant differences in the quality parameters before and after fitting predictive models and ANOVA to compare the performances of RN and ANFIS on different water quality parameters. It is expected that the results will allow the implementation of real-time monitoring systems, contributing to the improvement of water quality in the institution.

Keywords: Machine learning, water quality, prediction, neural networks, ANFIS.

1 Introducción

Hay varias fuentes de agua tanto para beber como para riego, incluidos ríos, arroyos, lluvia y aguas subterráneas (a las que se accede a través de pozos y perforaciones). La naturaleza y las características de una fuente de agua son a menudo factores críticos que influyen en los componentes de las muestras de agua obtenidas en ella. Más allá de los



factores naturales, los desechos químicos de actividades humanas como la minería, la extracción de petróleo crudo y los desechos industriales, con mayor frecuencia terminan en arroyos, ríos y otras fuentes de agua, cambiando la naturaleza y las propiedades de estas aguas [3]. La posible contaminación de este recurso representa un riesgo significativo a nivel global, impulsando la necesidad de concienciación sobre la importancia de preservar este recurso, el monitoreo constante requiere de un proceso de concientización sobre el agotamiento del recurso, y su impacto económico, social y político [4]. Numerosos problemas de calidad del agua, como el drenaje ácido de las minas, la salinización y la sedimentación resultantes de las actividades mineras, y problemas de eutrofización y contaminación microbiana también persisten debido a fallas en las instalaciones de tratamiento de aguas residuales [5] además, la cantidad limitada de datos sobre la calidad del agua (CA) se atribuye principalmente a una capacidad limitada de seguimiento y presentación de informes, especialmente en los países subdesarrollados [6]. Con ello nos damos cuenta acerca de la problemática actual que estamos enfrentando debido a la falta de información y métricas acerca de la calidad del agua. Esto resalta la importancia de desarrollar soluciones más eficientes y accesibles, especialmente cuando se trata de garantizar agua de calidad para las personas, un recurso esencial para la vida y la salud

En [7] se pudo demostrar la efectividad de los métodos de aprendizaje con respecto a los métodos tradicionales y con la ayuda de los sensores de IoT se mejoró la recopilación de datos en tiempo real a diferencia del muestreo manual que consumen mayor tiempo y son propensos a errores, y con ello se pudo comprender los factores que afectaban el crecimiento de las algas. Además, en [3] propuso un sistema de red con sensores en presas y tratamientos de agua, así mismo se consideraron 3 modelos de aprendizaje automático los cuales procesaban los datos enviados a través de los sensores, estos resultados indicaban los índices de la calidad del agua (WQI e IWQI) para determinar las propiedades adecuadas del agua para el consumo humano y riego. En [8] se desarrolló un proyecto en el análisis y calidad del agua, mediante sensores se obtuvieron resultados que fueron enviados para ser limpiados, normalizados y analizados utilizando técnicas de aprendizaje automático y con ello se evaluaron los resultados con métricas de validación, esto produjo una mejora en la precisión de datos, monitoreo continuo, reducción de costos y acceso a datos remotos. Con respecto a [9] para evaluar y monitorear la calidad del agua superficial es necesario utilizar técnicas de inteligencia artificial especialmente de aprendizaje automático como las redes neuronales, el objetivo de ese proyecto fue categorizar y predecir el índice de calidad de agua y con ello se obtuvieron resultados óptimos en la precisión de la predicción, también se pudo identificar tendencias o patrones que permitieron mejorar el monitoreo y por último estos datos fueron visualizados en un mapa de calor donde se observa claramente las fluctuaciones geográficas de estos parámetros con respecto al ICA. Se menciona en [10] que para poder análisis la calidad de agua implementaron mediante sensores que capturaban la información y posterior mente lo enviaban a la nube donde los modelos automáticos operaban para clasificarlos, para el entrenamiento usaron un conjunto de datos multiclase de China lo cual ayudo a la precisión a la hora de analizar la calidad del agua

Como sabemos, la calidad del agua potable es un aspecto crítico para garantizar la salud de las comunidades académicas y mejorar el bienestar general. En la Universidad Nacional Micaela Bastidas de Apurímac (UNAMBA), la calidad del agua que llega a sus instalaciones es fundamental para las actividades diarias de estudiantes y personal. Sin embargo, no existe un sistema eficiente de monitoreo en tiempo real que permita evaluar esta calidad de manera continua. Por ello, este proyecto busca desarrollar un modelo predictivo basado en aprendizaje automático que optimice este proceso [2]. Por ende, se identificó una problemática en la falta de un sistema automatizado de monitoreo de calidad de agua en la UNAMBA. debido a que los métodos tradicionales de monitoreo y predicción de la calidad del agua a menudo están limitados por su costo, su consumo de tiempo y su incapacidad para capturar datos en tiempo real [8]. Con esta problemática nace la idea de diseñar y evaluar modelos predictivos basados en aprendizaje automático para estimar la calidad del agua potable en la UNAMBA, para ello se recopilará y analizará muestras de agua directamente de las instalaciones de la UNAMBA, también se desarrollará modelos predictivos basados en RN y ANFIS. Para ello evaluaremos el rendimiento de los modelos mediante métricas estándar y por último validaremos la eficacia de los modelos en condiciones locales de operación.

1.1 Evaluación de la calidad del agua

Abordar estos desafíos ambientales requiere un enfoque integral que combine experiencia científica, colaboración de las partes interesadas y recursos adecuados [8]. Esto significa que al querer solucionar este tipo de problemas con respecto a la calidad del agua no solo debemos basarnos en ciencia o tecnología, sino usar ambas áreas para generar una solución eficiente y funcional. Con ello, la implementación de IoT permite el despliegue de redes de sensores en cuerpos de agua, recopilando una gran cantidad de datos sobre diversos parámetros de calidad del agua (WQP) [8]. Esto representa un avance significativo y una gran importancia debido a que el agua para el consumo humano debe seguir ciertos criterios indispensables en sus parámetros. La figura 1 muestra los escenarios de evaluación de la calidad del agua.

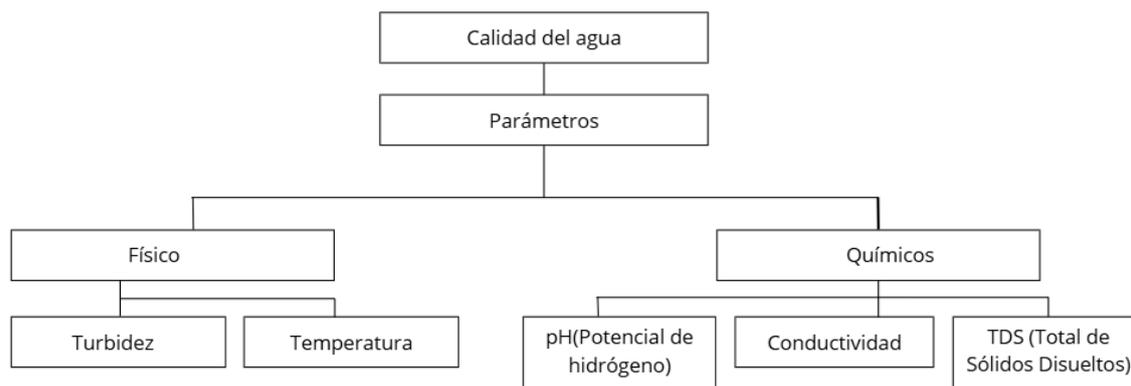


Figura 1. Evaluación para calidad de agua.

La variable turbidez proporciona una visión fundamental del estado del agua, la temperatura indicará si el agua es potencialmente apta para la proliferación de bacterias, la variable OPR se analiza para descartar una contaminación por bacterias y los valores del sensor TDS, permiten discriminar el origen de la turbiedad del agua [11].

Además, se medirá la acidez del agua el pH, el ORP, la conductividad, la temperatura y la presión barométrica en el nivel de agua, que son factores para considerar a la hora de evaluar la calidad del agua para consumo humano [12]. Por ende, consideramos cruciales estos parámetros para analizar la calidad del agua como se muestra en la Figura 1.

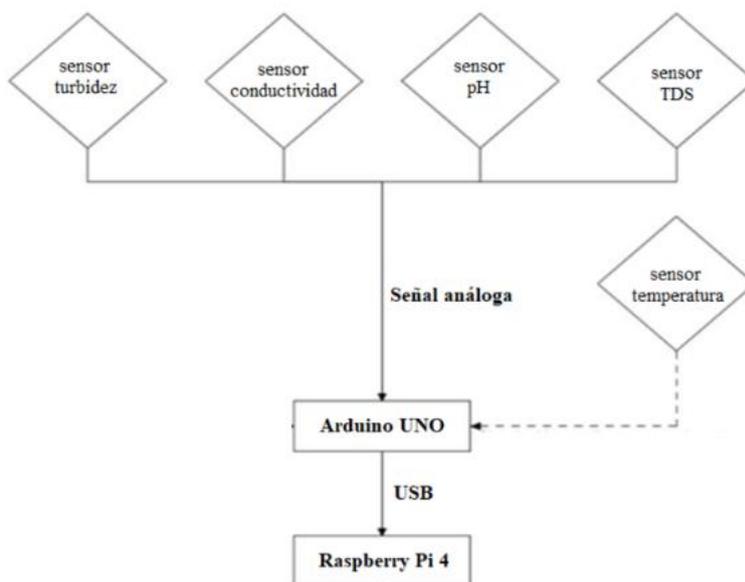


Figura 2. Diseño del diagrama de procesos

La elección del microcontrolador es una decisión importante en cualquier proyecto electrónico, de él depende el resto del sistema y, por tanto, hay ciertos requisitos que se deben cumplir para que el sistema funcione correctamente. Estos requisitos suelen ser de memoria, de números de pines o que sea capaz de implementar de forma sencilla protocolos de comunicación [12]. Para nuestro proyecto hemos considerado al Arduino Uno que se encargará de obtener los datos recopilados de los sensores y el Raspberry como se muestra en la Figura 2, el cual obtendrá los datos del Arduino a través de un USB para llevar a cabo los procesamientos más complejos que son el Machine Learning.

1.2 Modelo predictivo

Sistema de inferencia neuro difusa adaptativa (ANFIS): Es una combinación de sistema difuso y la capacidad de aprendizaje de las redes neuronales [13]. En lógica difusa, los datos de entrada se convierten en valores difusos mediante el empleo de funciones de pertenencia. Los valores difusos están comprendidos entre 0 y 1.

En ANFIS, las reglas se definen en función de sus antecedentes (Si parte) y consecuentes (Entonces parte) y estas reglas se almacenan en un sistema de reglas difusas (las reglas 'SI-ENTONCES'). Las dos ecuaciones (1 y 2) muestran las reglas para un modelo ANFIS de Sugeno con dos entradas (x e y) y una salida f .

$$\text{Regla 1: Si } x \text{ es } P_1 \text{ y es } Q_1; \text{ entonces } f_1 = p_1x + q_1y + r_1 \quad (1)$$

$$\text{Regla 2: Si } x \text{ es } P_2 \text{ y es } Q_2; \text{ entonces } f_2 = p_2x + q_2y + r_2 \quad (2)$$

Pi y Qi son conjuntos difusos, fi representa la salida dentro de la región difusa y pi, qi y ri son los parámetros de diseño determinados durante el proceso de entrenamiento, La figura 3 muestra la arquitectura de un ANFIS con dos entradas (x e y) y una salida (f).

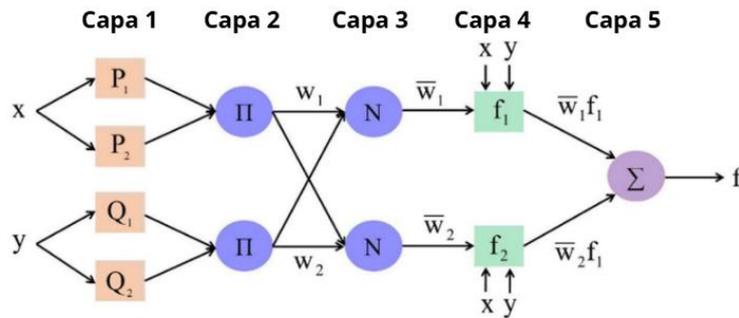


Figura 3. Arquitectura del modelo ANFIS con 2 entradas y 5 capas

2 Método

Las variables que se tomaron en consideración fueron, como variable dependiente: La calidad del agua potable, medida a través de parámetros fisicoquímicos y biológicos como pH, turbidez, oxígeno disuelto, nitrógeno y coliformes fecales. El desempeño del modelo se evaluará utilizando métricas como RMSE, MAE y R², que reflejarán la capacidad de los modelos para predecir con precisión estos parámetros. Las variables independientes: Los modelos predictivos basados en aprendizaje automático, específicamente Redes Neuronales (RN) y Sistemas Neuro-Difusos Adaptativos (ANFIS). Estas herramientas son las que se manipularán para evaluar su impacto en la predicción de la calidad del agua.

2.1 Tipo de investigación

Tipo de investigación será aplicada y cuantitativa porque se desarrollará un modelo de aprendizaje automático o Machine Learning que pueda analizar la calidad del agua en tiempo real mediante el uso de sensores. El diseño de la Investigación será experimental, se diseñará un experimento en el que se medirán los parámetros de la calidad del agua de la Universidad Nacional Micaela Bastidas de Apurímac red de distribución de JASS de Bancapata donde se obtendrán los datos que servirán para entrenar, validar y evaluar el modelo. Se comparará el los desempeños de los modelos de RN y ANFIS utilizando datos obtenidos directamente en la UNAMBA [14].

2.2 Instrumentos de recolección de datos

- Sistema de sensores integrados: Sensores de pH, turbidez, TDS y conductividad eléctrica para recopilar información de calidad del agua.
- Microcontroladores: Arduino uno, Raspberry Pi para capturar y transmitir datos de los sensores.
- Software de captura de datos: Excel o Firebase para registrar y almacenar las lecturas obtenidas.

2.3 Instrumentos de medición

- Sistema de sensores integrados: Sensores específicos para medir directamente pH, turbidez, TDS y conductividad eléctrica.
- Microcontroladores: Uso para operar y garantizar mediciones precisas de los sensores.

- Red de distribución de JAAS Bancapata: Análisis directo de la calidad del agua en puntos específicos de esta red.

2.4 Procedimiento propuesto

- A) Fase 1: Recopilación de datos
- Toma de muestras de agua en distintos puntos de las instalaciones de la UNAMBA (red de distribución de JAAS de Bancapata).
 - Análisis de parámetros como pH, turbidez, oxígeno disuelto, nitrógeno, y coliformes fecales.
- B) Fase 2: Preprocesamiento
- Depuración de los datos: Normalización de datos y eliminación de valores atípicos.
 - División de los datos en conjuntos de entrenamiento, validación y prueba [13]
- C) Fase 3: Desarrollo de los modelos
- Redes Neuronales: Configuración y ajuste de hiperparámetros utilizando TensorFlow [15].
 - ANFIS: Implementación de sistemas difusos en MATLAB para modelar incertidumbre [16].
- D) Fase 4: Evaluación
- Aplicación de métricas como RMSE, MAE y R^2 para comparar desempeños.
- E) Fase 5: Validación cruzada
- Uso de K-fold para garantizar la generalización de los modelos.

2.5 Población y muestra

La población que se usara es el agua de diversos puntos de las instalaciones de la Universidad Nacional Micaela Bastidas de Apurímac La muestra que se recolectará será de la red de distribución de JAAS de Bancapata. y será dividida en 2 uno para el entrenamiento de los modelos de aprendizaje y el otro para la validación del modelo
Criterio de exclusión: muestras de agua que no pertenezcan a la red de distribución de JAAS de Bancapata

2.6 Diseño estadístico

2.7 Para evaluar diferencias significativas en los parámetros de calidad antes y después del ajuste de modelos predictivos

- a) Hipótesis estadísticas:
- H_0 : No hay diferencia entre los parámetros de calidad antes y después del ajuste de modelos predictivos
 - H_1 : Hay diferencias entre los parámetros de calidad antes y después del ajuste de modelos predictivos
- b) Pruebas estadísticas
- Prueba t de Student: Se utilizará para comparar el promedio de la calidad del agua antes y después del ajuste de los modelos predictivos

$$t = \frac{\bar{d}}{\frac{sd}{\sqrt{n}}} \quad (3)$$

- c) Nivel de significancia (α): 5%

2.8 Para comparar los desempeños de RN y ANFIS en diferentes parámetros de calidad del agua

- a) Hipótesis estadísticas:
- H_0 : No hay diferencia significativa entre los modelos RN y ANFIS en la calidad del agua
 - H_1 : Existe una diferencia significativa entre los modelos RN y ANFIS en la calidad del agua

b) Pruebas estadísticas

- Prueba de ANOVA: Se utilizará para comparar los desempeños de RN y ANFIS en diferentes parámetros de calidad del agua, usando los diferentes parámetros. Para medir su desempeño se usará el error cuadrático medio o RMSE

Formula para hallar el error cuadrático medio

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (4)$$

Formula de ANOVA

$$F = \frac{\text{Variabilidad entre los modelos (RN y ANFIS)}}{\text{Variabilidad dentro de los modelos}} \quad (5)$$

c) Nivel de significancia (α): 5%

2.9 Herramientas

- Análisis del agua de la UNAMBA [15]
- MATLAB para el desarrollo de ANFIS [16]
- Python y TensorFlow para las RN [17]

3 Discusiones esperadas

Se anticipa que las RN demuestren mejor rendimiento en escenarios con relaciones no lineales complejas, mientras que ANFIS será más robusto en situaciones de incertidumbre. Los resultados incluirán:

- Gráficos comparativos: Curvas de aprendizaje y diagramas de barras que muestren RMSE y MAE para cada modelo [17].
- Tablas resumen: Comparación de desempeño de RN y ANFIS en distintas variables.
- Validaciones cruzadas: Indicadores de generalización [15].
- Análisis estadístico: Confirmación de diferencias significativas en los resultados mediante pruebas T y ANOVA [1].

4 Conclusiones esperadas

Se espera que los resultados respalden el uso de aprendizaje automático como herramienta clave para el monitoreo de calidad del agua en la UNAMBA. Los estudios de [14]-[1] sugieren que estas técnicas superaron los enfoques tradicionales a la hora de comparar en la rapidez y precisión. Estos hallazgos pueden sentar las bases para la implementación de sistemas de monitoreo continuo en la universidad [16]. Desafíos potenciales, variabilidad en las condiciones locales del agua, dependencia de la calidad inicial de los datos obtenidos.

Se prevé que el aprendizaje automático ofrezca soluciones viables para la gestión de calidad del agua en la UNAMBA, destacándose:

- RN: Mayor precisión en relaciones no lineales complejas [1].
- ANFIS: Mejor capacidad para manejar incertidumbre en los datos [13].
- Contribuciones: Desarrollo de un sistema de monitoreo en tiempo real adaptado a las condiciones específicas en la universidad [16]-[17].

5 Agradecimiento

Estamos agradecidos con Vicerrectorado de Investigación, así mismo con nuestra alma mater que es la magnánima Universidad Nacional Micaela Bastidas de Apurímac. También expresamos nuestra gratitud a nuestros asesores Erech Ordoñez Ramos y Alejandrina Huaylla Quispe, quienes nos brindaron los recursos necesarios y su apoyo constante para

el desarrollo del trabajo. Así mismo, esta agradable experiencia nos sirvió para tener un enfoque más relevante de nuestra carrera y de esta manera seguir desarrollando proyectos innovadores, contribuyendo con el desarrollo tecnológico.

6 Referencias

- [1] X. Zhang, L. Yao, X. Wang, J. Monaghan, D. McAlpine, and Y. Zhang, "A survey on deep learning-based non-invasive brain signals: recent advances and new frontiers," *J Neural Eng*, vol. 18, no. 3, p. 031002, 2021, doi: 10.1088/1741-2552/abc902.
- [2] M. RadFard *et al.*, "Protocol for the estimation of drinking water quality index (DWQI)in water resources: Artificial neural network (ANFIS)and Arc-Gis," *MethodsX*, vol. 6, pp. 1021–1029, Jan. 2019, doi: 10.1016/j.mex.2019.04.027.
- [3] O. O. Ajayi, A. B. Bagula, H. C. Maluleke, Z. Gaffoor, N. Jovanovic, and K. C. Pietersen, "WaterNet: A Network for Monitoring and Assessing Water Quality for Drinking and Irrigation Purposes," *IEEE Access*, vol. 10, pp. 48318–48337, 2022, doi: 10.1109/ACCESS.2022.3172274.
- [4] R. G. Zhindon-Almeida, R. A. Sánchez-Ancajima, and W. J. Castañeda-Guzmán, "Análisis estadístico de parámetros de calidad del agua del Estero El Macho en la ciudad de Machala-Ecuador.," *Revista de Ciencias Sociales (13159518)*, vol. 30, pp. 489-489–513, 2024, [Online]. Available: <https://search.ebscohost.com/login.aspx?direct=true&db=fap&AN=179635399&site=eds-live>
- [5] J. T. Sindane and L.-A. S. Modley, "The impacts of poor water quality on the residential areas of Emfuleni local municipality: a case study of perceptions in the Rietspruit River catchment in South Africa," *Urban Water J*, vol. 20, no. 10, pp. 1568–1578, Nov. 2023, doi: 10.1080/1573062X.2022.2030763.
- [6] G. A. Lopez-Ramirez and A. Aragon-Zavala, "Wireless Sensor Networks for Water Quality Monitoring: A Comprehensive Review," *IEEE Access*, vol. 11, pp. 95120–95142, 2023, doi: 10.1109/ACCESS.2023.3308905.
- [7] N. A. P. Rostam, N. H. A. H. Malim, R. Abdullah, A. L. Ahmad, B. S. Ooi, and D. J. C. Chan, "A Complete Proposed Framework for Coastal Water Quality Monitoring System with Algae Predictive Model," *IEEE Access*, vol. 9, pp. 108249–108265, 2021, doi: 10.1109/ACCESS.2021.3102044.
- [8] M. A. Rahu, A. F. Chandio, K. Aurangzeb, S. Karim, M. Alhussein, and M. S. Anwar, "Toward Design of Internet of Things and Machine Learning-Enabled Frameworks for Analysis and Prediction of Water Quality," *IEEE Access*, vol. 11, pp. 101055–101086, 2023, doi: 10.1109/ACCESS.2023.3315649.
- [9] 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.
- [10] Md. S. Bin Shahid *et al.*, "Hypertuning-Based Ensemble Machine Learning Approach for Real-Time Water Quality Monitoring and Prediction.," *Applied Sciences (2076-3417)*, vol. 14, no. 19, pp. 8622-8622–8640, 2024, doi: 10.3390/app14198622.
- [11] A. Conejeros Molina, H. Pichunman, B. L. Martinez-Jimenez, and A. P. Remior, "Monitoreo de calidad del agua en sistema de agua potable rural," 2021.
- [12] A. Rodríguez Rodríguez, J. R. Vento Álvarez, J. Garrido González, and V. Rodríguez Benitez, "Monitoring tool for water quality and quick alert of flooding," *Sistemas y Telemática*, vol. 16, no. 44, pp. 25–34, Feb. 2018, doi: 10.18046/syt.v16i44.2725.
- [13] Z. M. Yaseen, M. M. Ramal, L. Diop, O. Jaafar, V. Demir, and O. Kisi, "Hybrid Adaptive Neuro-Fuzzy Models for Water Quality Index Estimation," *Water Resources Management*, vol. 32, no. 7, pp. 2227–2245, May 2018, doi: 10.1007/s11269-018-1915-7.
- [14] World Health Organizatio, "SAFER WATER, BETTER HEALTH," *World Health Organizatio*, 2019, Accessed: Dec. 28, 2024. [Online]. Available: <https://iris.who.int/bitstream/handle/10665/329905/9789241516891-eng.pdf>
- [15] S. Zhu and S. Heddam, "Prediction of dissolved oxygen in urban rivers at the three Gorges reservoir, China: Extreme learning machines (ELM) versus artificial neural network (ANN)," *Water Quality Research Journal*, vol. 55, no. 1, pp. 106–118, Feb. 2020, doi: 10.2166/WQRJ.2019.053.
- [16] S. H. Ewaid, S. A. Abed, and S. A. Kadhum, "Predicting the Tigris River water quality within Baghdad, Iraq by using water quality index and regression analysis," *Environ Technol Innov*, vol. 11, pp. 390-390–398, 2018, doi: 10.1016/j.eti.2018.06.013.
- [17] A. Azad, H. Karami, S. Farzin, S. F. Mousavi, and O. Kisi, "Modeling river water quality parameters using modified adaptive neuro fuzzy inference system," *Water Science and Engineering*, vol. 12, no. 1, pp. 45–54, Mar. 2019, doi: 10.1016/j.wse.2018.11.001.