

Drinking water treatment based on Artificial Intelligence and Internet of Things

Jhair Stiffe Benites Villanueva, Estudiante¹, Diego Almagro Guerra Chavez, Estudiante¹, Jordan Jhonny Jara Alvarado, Estudiante¹, Jhonatan Javier Lloclla Mamani, Estudiante¹, Celso Alejandro Miranda Horna, Estudiante¹, Dany Jhon Poma Arriguela, Estudiante¹, Yvan Huaricallo Vilca, Maestro en dirección de la Construcción^{1,2},
¹Departamento de ingeniería Civil, Universidad Nacional Mayor de San Marcos, Perú, ² Universidad Privada del Norte, Perú, jhair.benites@unmsm.edu.pe, diegoalmagro.guerra@unmsm.edu.pe, jordan.jara@unmsm.edu.pe, jhonatan.lloclla@unmsm.edu.pe, celso.miranda@unmsm.edu.pe, dany.poma@unmsm.edu.pe, yhuaricallov@unmsm.edu.pe, yvan.huaricallo@upn.pe

Abstract

Water is one of the essential natural resources for life, found in lakes, lagoons, and other sources. However, for consumption, it needs to be treated, and that is where drinking water treatment plants come into play. These plants can enhance their functionality by using modern tools such as Artificial Intelligence (AI) and the Internet of Things (IoT). The article discusses how these techniques, including machine learning, neural networks, support vector machines, neuro-fuzzy inference systems, and fuzzy logic, can improve the prediction of water quality and demand, optimize the process of drinking water treatment, and control water quality parameters. The methodology used for this study involved a systematic review of various bibliographic sources, scientific journal databases, and academic articles from platforms such as Scopus, IEEE, ScienceDirect, among others. Based on the review, the study determined the most influential water quality parameters and the most effective techniques of AI and IoT to predict, optimize, and control water quality in a drinking water treatment plant. As a result of the research, a flowchart was developed, representing the proposed methodology for the operation of an intelligent system in a drinking water treatment plant based on the most effective techniques of AI and IoT, achieving the purpose of the article. It is worth noting that some of the results obtained were: 100% water quality classification accuracy (FFNN) with respect to the prediction of water quality data, 99.2% success rate for efficiency improvement in the optimization of treatment processes using genetic algorithms and 97.77% effectiveness for the control of water quality parameters using neural networks. Furthermore, this article can serve as a guide for those interested in implementing an intelligent system in a drinking water treatment plant based on artificial intelligence and the Internet of Things.

Keywords: *Artificial Intelligence (AI), Internet of things (IoT), drinking water treatment plant, water treatment, artificial neuronal network (ANN).*

Tratamiento de agua potable basado en Inteligencia Artificial e Internet de las Cosas

Jhair Stiffe Benites Villanueva, Estudiante¹, Diego Almagro Guerra Chavez, Estudiante¹, Jordan Jhonny Jara Alvarado, Estudiante¹, Jhonatan Javier Lloclla Mamani, Estudiante¹, Celso Alejandro Miranda Horna, Estudiante¹, Dany Jhon Poma Arriguella, Estudiante¹, Yvan Huaricallo Vilca, Maestro en dirección de la Construcción^{1,2},
¹Departamento de ingeniería Civil, Universidad Nacional Mayor de San Marcos, Perú, ² Universidad Privada del Norte, Perú, jhair.benites@unmsm.edu.pe, diegoalmagro.guerra@unmsm.edu.pe, jordan.jara@unmsm.edu.pe, jhonatan.lloclla@unmsm.edu.pe, celso.miranda@unmsm.edu.pe, dany.poma@unmsm.edu.pe, yhuaricallo@unmsm.edu.pe, yvan.huaricallo@upn.pe

Resumen

El agua es uno de los recursos naturales esenciales para la vida, podemos encontrarla en lagos, lagunas y demás fuentes, sin embargo, para su consumo debemos de potabilizarla y bajo ese contexto es que aparecen las plantas de tratamiento de agua potable; las cuales pueden mejorar su funcionalidad utilizando herramientas modernas como las técnicas de Inteligencia Artificial e Internet de las Cosas. El artículo trata sobre cómo dichas técnicas (entre ellas, el aprendizaje automático, las redes neuronales, las máquinas de vectores de soporte, los sistemas de inferencia neurodifusa y la lógica difusa) pueden generar mayor eficiencia en la predicción de datos de calidad y demanda del agua, optimización del proceso de tratamiento de agua potable y control de parámetros de calidad del agua. La metodología usada para el desarrollo del presente fue la revisión sistemática de diferentes fuentes bibliográficas, bases de datos de revistas científicas y artículos académicos como Scopus, IEEE, ScienceDirect, entre otras. En base a la revisión se determinó los parámetros de calidad de agua de mayor incidencia y las técnicas de mayor efectividad de Inteligencia artificial e Internet de las Cosas para predecir, optimizar y controlar la calidad del agua en una planta de tratamiento de agua potable. Como resultados de la investigación se obtuvo un flujograma que representa la propuesta de metodología del funcionamiento de un sistema inteligente en una planta de tratamiento de agua potable basados en las técnicas más efectivas de Inteligencia Artificial e Internet de las Cosas que logra cumplir con el propósito del artículo. Cabe destacar que algunos de los resultados obtenidos fueron: una precisión de clasificación de calidad del agua (FFNN) del 100% respecto a la predicción de datos de calidad del agua, un 99.2% de éxito para la mejora de la eficiencia en la optimización de procesos de tratamiento usando algoritmos genéticos y un 97.77% de efectividad para el control de parámetros de calidad de agua usando las redes neuronales. Además, este artículo puede proporcionar una guía para los que deseen implementar un sistema inteligente en una planta de tratamiento de agua potable basado en inteligencia artificial e Internet de las Cosas.

Palabras clave: Inteligencia Artificial (IA), Internet de las Cosas (IoT), Planta de tratamiento de agua potable (PTAP), tratamiento de agua, Red Neuronal Artificial (RNA).

I. INTRODUCCIÓN

El agua es esencial para los humanos, pero según lo indicado por [1] solo el 2.5% es agua dulce y por lo tanto es apta para consumo. El agua tratada adecuadamente es vital para la higiene y la prevención de enfermedades. En 2020, solo el 74% de la población mundial tenía acceso a un suministro

de agua segura, mientras que más de 2000 millones consumían agua de fuentes contaminadas, según lo indicado en [2]. Esto ocasiona un riesgo en cuanto a salubridad y transmisión de enfermedades como la diarrea, el cólera, la disentería, la fiebre tifoidea y la poliomielitis.

Dado lo visto en [3], las plantas de tratamiento de agua potable (PTAP) tiene por objetivo tratar el agua y hacerlas apta para el consumo. Las PTAP eliminan impurezas como turbiedad, sedimentos, microorganismos, dureza, olor y otras características que presente el agua cruda, asegurando que los ciudadanos consuman agua que cumpla con los estándares de calidad de su país.

Existen muchos factores que influyen en el tratamiento del agua potable, entre ellos tenemos la turbiedad del agua, el pH y la temperatura.

El crecimiento poblacional y el cambio climático han ocasionado que el tratamiento de esta sea más dificultoso. Sin embargo, en estudios recientes sobre la aplicación de la inteligencia artificial (IA), el Internet de las Cosas (IoT) y la utilización de nuevas tecnologías electrónicas aplicadas en los procesos de predicción, control y seguimiento de procesos, por ejemplo, en sistemas de almacenamiento de energía térmica se demostró una mejora en su eficiencia y automatización [4].

El uso de la IA y sus técnicas también han tenido resultados favorables en otros campos como la medicina, el transporte e incluso en el tratamiento de agua. Ejemplo en Seúl (Corea del Sur), investigadores emplearon un modelo combinado de la técnica del mapa autoorganizado (SOM) y los modelos difusos de C-medias (FCM) para analizar la calidad de agua subterráneas urbanas en su ciudad [5]. Otro ejemplo es en Irán, la aplicación redes neuronales artificiales (RNA) difusa, enfoque de red neuronal probabilística (RNP) y funciones de base radial para analizar la calidad anual del agua potable en el acuífero de Irán y su asociación con la incidencia de las sequías [6].

El aprendizaje automático es otra de las disciplinas que tiene un énfasis especial en resolver problemas y mejorar el rendimiento de los sistemas informáticos a través de la generación de modelos matemáticos mediante el análisis de datos [7]. El uso de la IA y sus técnicas de aprendizaje autónomo ya han tenido frutos en otros campos como el energético. [4], menciona en su artículo sobre como la IA y sus técnicas: redes neuronales, algoritmos genéticos, lógica difusa

y máquinas de vectores de soporte; se utilizan para mejorar la precisión en la predicción de la disponibilidad y demanda de energía térmica. Por lo visto anteriormente, resulta entonces factible que esta disciplina se extienda también a campos del tratamiento de agua potable.

Predecir y monitorear la calidad del agua con Inteligencia Artificial es una tendencia que ha cobrado atención. Sin embargo, muchas de estas técnicas no consideran la aplicabilidad en diferentes usos del recurso hídrico [8]. Para abordar esta limitación, se propone enfoques como el uso de Árboles de Decisión en IA, que ofrecen ventajas en comprensión y facilidad de uso [9]. Casos puntuales de éxito incluyen la determinación de la potabilidad del agua mediante árboles de decisión [10] y la implementación de sistemas inteligentes de monitoreo y control en tanques de reserva y redes inalámbricas para la optimización de la dosificación de cloro.

El Internet de las Cosas (IoT), según el artículo [11], ofrece beneficios como la transferencia rápida de información, comunicación directa con el entorno, ahorro energético y optimización de procesos. Singapur ha experimentado un progreso significativo al convertirse en investigadores y desarrolladores de tecnología. Sin embargo, el IoT también presenta peligros, como la divulgación de datos personales y configuraciones de dispositivos en servidores desconocidos, lo que dificulta su adopción en grandes industrias [12]. Además, las limitaciones económicas, falta de políticas energéticas y marcos regulatorios generan falta de confianza en las inversiones, llevando a retrasos o cancelaciones de proyectos en IoT [13]

A. Internet de las Cosas (IoT)

El Internet de las Cosas, para [14], aborda diversas tecnologías como sensores, comunicación inalámbrica, como puede ser el control, seguimiento y monitoreo de cosas (variables atmosféricas, químicas, físicas, virtuales, y todo aquello en donde se pueda obtener información en forma de valores). Cabe mencionar que este el término “cosas” hace referencia a todo aquel objeto que puede ser reconocible, localizable, ubicable y controlable por medio del Internet, tal como señala [14]. Así mismo, existen diferentes categorías de interconexión que son aplicables bajo el enfoque del Internet de las Cosas, entre ellas podemos mencionar, máquinas con máquinas (M2M, machine to machine), personas con máquinas (P2M, people to machine) y personas con personas (P2P, people to people).

B. Parámetros del agua potabilizada

En [15], menciona que es necesario que el agua presente un equilibrio adecuado de sales, iones y minerales, siempre y cuando se mantengan dentro de los límites aceptables. En [16] nos proporciona todos los parámetros establecidos para la potabilización del agua, pero nos centraremos en los parámetros de mayor incidencia que son relevantes y que se consideran de igual forma para otros países:

- **Turbidez:** Se refiere a la presencia de partículas suspendidas y sólidos en ella. Se mide en unidades nefelométricas de turbidez (UNT). Para asegurar la potabilidad del agua, se busca mantener la turbidez generalmente entre 1 y 5 UNT.

- **pH:** Es una medida que indica la acidez o alcalinidad del agua. Para la potabilización, el pH se debe encontrar generalmente entre 6.5 y 8.5.

- **Cloro residual:** Se refiere a la cantidad de cloro que permanece en el agua después del proceso de desinfección. El límite máximo permisible es conductividad eléctrica entre 0.2 y 0.5 mg/l para la protección continua contra bacterias y virus.

- **Conductividad eléctrica:** Capacidad del agua para conducir la corriente eléctrica. En el Perú para la conductividad se toma en una temperatura de 25°C y se mide en $\mu\text{mho/cm}$ (micro-mho por centímetro). Se busca mantener la conductividad baja, en valores inferiores a 1500 $\mu\text{S/cm}$.

- **Coliformes totales y coliformes fecales:** Son un grupo de bacterias que se encuentran comúnmente en el intestino de animales de sangre caliente, incluyendo seres humanos. Los límites varían según la regulación, pero generalmente solo se acepta valores de 0.

En [17] las aguas superficiales se dividen en 3 tipos, los cuales se usan diferentes tratamientos y los parámetros también varían. Para uno de ellos el pH oscila entre los valores de 5.5 y 9 y su tratamiento a realizar sería afino y desinfección. De las tablas que proporciona en su trabajo podemos concluir que al encontrar mayor pH se requerirá mayor cantidad y de complejos tratamientos.

Para [18], el valor medio es de 7.24, el cual está acorde con lo que establece la norma boliviana 512 y menciona, "está en relación con parámetros establecidos como son de 6,5 a 9". Además, según la Organización Mundial de Salud, "La relación del pH del agua potable entre las ciudades de la Paz y El Alto muestra valores de 7,22 y de 7,28 respectivamente".

C. Procesos de potabilización (mejoramiento del nivel de cloro y pH)

Como se menciona en [19], la planta de tratamiento de agua potable (PTAP) son un conjunto de equipos, materiales y estructuras, el cual lo utilizamos para convertir las propiedades y características físicas, químicas y microbiológicas del agua cruda en agua apta para el consumo. El pH del agua potable varía según su origen y tratamiento, y se recomienda que esté en un rango de 6.5 a 8.5 para garantizar su seguridad y calidad.

Para [20], describen la generación de aguas ácidas de mina y las alternativas de tratamiento, centrándose en el proceso de neutralización química como una opción adecuada para su remediación. Estos sistemas combinan procesos naturales físicos, químicos y biológicos. Se añaden sustancias químicas, como soda cáustica para aumentar el pH bajo o ácido clorhídrico para disminuir el pH alto. El procedimiento implica seleccionar sustancias químicas y dosificarlas para ajustar el

pH deseado, utilizando un sistema de dosificación apropiado y realizando un seguimiento y control continuo.

En [21] la cloración es un proceso mediante el cual se aplica cloro o compuestos de cloro al agua con el objetivo de eliminar microorganismos y patógenos. La cloración del agua, al agregar productos clorados como pastillas de cloro o lejía, elimina estos microbios, reduciendo el riesgo de enfermedades transmitidas por el agua. La concentración de cloro libre debe ser de 0.2 a 0.5 mg/l según la OMS. Sin embargo, la cloración no purifica completamente el agua ni elimina ciertos parásitos, por lo que se requieren métodos adicionales para una purificación total

D. Potabilización en la Industria 4.0

La utilización de tecnología moderna es beneficiosa, para esto nos podemos avalar de dicho por [22], que menciona que se ha comprobado que la automatización de procedimientos y maquinarias en instalaciones produce grandes ventajas en su funcionamiento. Bajo lo mencionado anteriormente, resulta importante denotar que algunas de estas grandes ventajas son la aceleración de los procesos y la reducción de los costos operativos en procesos habituales. En el artículo [22] también menciona que las tecnologías nuevas pueden manifestarse como por ejemplo en la inteligencia artificial (IA), así como en aprendizaje automático (ML). Estas tecnologías son parte de la industria 4.0 y son aplicables para optimizar procesos en empresas de servicios, permitiendo dejar atrás sistemas e infraestructuras obsoletas.

Además, de acuerdo con [23], la implementación de nuevas tecnologías como podría tratarse de un sistema de control y monitoreo en una planta de tratamiento de agua utilizando IA e IoT, debería ser capaz de recopilar datos válidos y correctos.

E. Sensores

Existen diversos estudios sobre la aplicación de los sensores e IoT en el monitoreo y control de los parámetros de calidad agua, tal como se resume en la Tabla N°1. “Estudios de aplicación de sensores e IoT en el control del agua”. En [24], [25] los autores concluyen en lo mismo, la aplicación de sensores y IoT permite vincular la información y tener una visualización precisa e instantánea del estado del agua para poder realizar decisiones más rápidas. Además, también se emite alertas en tiempo real cuando los valores obtenidos están fuera de los rangos preestablecidos [26]. Obteniendo así un control más eficiente [23], [27]

La validez de los datos recolectados es sumamente importante para la toma de decisiones. En [23], los autores ubican 3 módulos de sensores en la planta de tratamiento de agua potable, pero la validez de estos datos solo se puede demostrar con un cuarto módulo que no toma medición alguna, pero se encarga de coordinar y comparar la información obtenida por los demás módulos para luego descartar las mediciones que no sean lógicas y conservar las que sí lo son.

Otro método para demostrar que los resultados obtenidos por un sistema inteligente de monitoreo y control para una planta de tratamiento de agua potable son válidos es mediante

el uso de equipos de laboratorio que determinen el valor de variables y luego compararlos con los obtenidos por el sistema, según lo indicado en [28].

Sin embargo, la validez de datos no sería suficiente para un eficiente control si no se cuenta con la información de manera instantánea. En [24], se implementa el sistema IoT para supervisar y controlar parámetros como temperatura, humedad, pH y nutrientes en el cultivo de Lechuga Orgánica en su Sistema Aeropónico. Estos sensores ofrecen la posibilidad de conectarse a una plataforma de Internet de las Cosas (IoT), lo que permite la recolección de datos en tiempo real, la visualización de dichos datos y la recepción de alertas instantáneas en caso de que los niveles de pH, turbidez, nivel de agua o temperatura se desvíen de los rangos deseados. La integración con IoT brinda a los agricultores una valiosa herramienta para monitorear y controlar de manera eficiente los parámetros críticos del cultivo, que también se aplica al tratamiento de agua potable.

Con la plataforma IoT, los profesionales acceden a una interfaz personalizada para supervisar datos en tiempo real y recibir notificaciones en sus dispositivos móviles o computadoras, lo que facilita la toma de decisiones rápidas basadas en parámetros clave.

TABLA 1
ESTUDIOS DE APLICACIÓN DE SENSORES E IOT EN EL CONTROL DEL AGUA

Autor	Sensor / Parámetro	Sistema de Comunicación	Uso del Agua	Resultados
[24]	- pH - Turbidez - Nivel de agua - Temperatura	Sistema Aeropónico o (MySQL)	Uso agrícola	Permite vincular a información con dispositivos Android y dar alertas instantáneas cuando se superan los parámetros: pH: 5.5 - 7.5 Turbidez: 1 - 20 NTU Nivel de agua: 30 - 40 cm (reposo) Temperatura: 21-28 °C
[25]	- Caudal de agua	Lora-WAN (Ubidots)	Agua Potable	Permite tener una visualización precisa y en tiempo real del caudal. El sensor permite leer rangos de: Caudal: 1-30 l/min
[26]	- pH - Turbidez - Sólidos disueltos - Conductividad - Temperatura	Node-RED (IBM Cloud)	Agua Potable	Permite tener un control instantáneo y mandar alarmas cuando se esté fuera del rango: pH: 6.5 - 8.5 Conductividad: < 0.7 dS/m Turbidez: 0 - 10 NTU Sólidos disueltos: < 300 PPM Temperatura: 15 - 45 °C
[27]	- pH - Temperatura	Red ZigBee	Agua Potable	Se obtuvo un control eficiente, sin embargo, con un poco de latencia. Los parámetros que utilizaban para el control fueron: pH: 2 - 8 Temperatura: 0 - 100 °C (0.05°C precisión)
[23]	- pH - Turbidez - Temperatura	Red ZigBee	Agua Potable	Se obtuvo un control eficiente, sin embargo, con un poco de latencia. Los parámetros que utilizaban para el control fueron: pH: 2 - 8 Temperatura: 0 - 100 °C (0.05°C precisión) Turbidez: 0 - 10 NTU

En la Tabla 1 se realizó un resumen de los sensores que más se utilizan, según el parámetro de agua que se analiza y su tipo de uso. También se identificó el sistema de IoT que utilizan, el tipo de sistema de comunicación, esto para comparar la eficiencia de cada uno. Además, se analizó el rango de valores que tiene cada sensor, esto con la finalidad de compararlos con los rangos utilizados por el Perú [16], [29]. En la Tabla 2 se muestra los parámetros y los límites máximos permisibles que se utilizaran en nuestra propuesta.

TABLA 2
LÍMITES MÁXIMOS PERMISIBLES DE PARÁMETROS DE CALIDAD ORGANOLÉPTICA.

Parámetros	Unidad de medida	Límite máximo permisible
Olor	---	Aceptable
Sabor	---	Aceptable
Color	UCV escala Pt/Co	15
Turbiedad	UNT	5
Temperatura	°C	<35
pH	Valor de pH	6.5 a 8.5

UCV = Unidad de color verdadero
UNT = Unidad nefelométrica de turbiedad

Nota: Tabla adaptada de [16], [29].

II. METODOLOGÍA

El objetivo principal del presente estudio es proponer la metodología de un sistema inteligente empleando las técnicas y métodos más confiables del IoT e IA para el monitoreo, predicción, control y optimización de una planta de tratamiento de agua potable.

En la investigación se establecieron los siguientes objetivos específicos: 1. Recopilar información sobre la implementación de sensores basados en IoT, 2. Determinar los parámetros de mayor incidencia en la potabilidad del agua, 3. Identificar la eficiencia de las técnicas del IoT e IA empleadas para el monitoreo, predicción, control y optimización de datos referentes a la calidad o tratamiento de agua, y 4. Diseñar un flujograma que emplee las técnicas y métodos más eficientes del IoT e IA en el proceso de una PTAP.

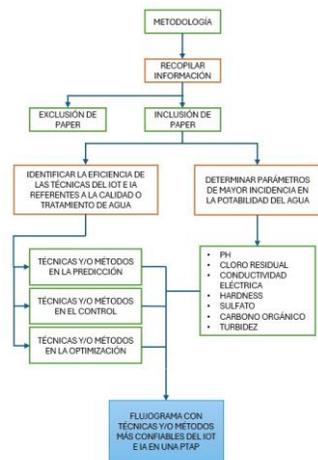


Fig. 1 Framework
Nota: Elaboración Propia

Elaboramos un Framework basado en nuestros objetivos, que incluye la recopilación de información y la selección de artículos para nuestra base de datos. Luego, agrupamos la información en temas relacionados con la calidad del agua y las técnicas de IA y IoT. Finalmente, desarrollamos un flujograma que propone el uso eficiente de IA, IoT y sensores en el tratamiento de agua en una PTAP.

Se utilizo diferentes fuentes bibliográficas, bases de datos de revistas científicas y artículos académicos como Scopus, IEEE, ScienceDirect, entre otras; para buscar información referente a la potabilización del agua empleando diversas técnicas del IA e IoT.

El procedimiento que se utilizó para la recolección de datos se detalla en la Tabla 3, es una revisión sistemática de hasta 15 años de antigüedad, la cual es una adaptación del método empleado en el artículo [4]. También, se definieron un total de 5 palabras claves, todas a la vez o en combinaciones, dependiendo de fuente de datos y así identificar las publicaciones más relevantes según cada una de las palabras clave.

TABLA 3
PROCEDIMIENTO PARA RECOPILOCIÓN DE DATOS.

Recogida de datos				
Base de datos	→	Scopus, ScienceDirect, ProQuest, Web of Science, Google Scholar, Fuentes Gubernamentales e Internacionales.	Fecha	→ 2008-2023
Palabras Clave	→	Inteligencia artificial (IA), Internet de las Cosas (IoT), Plantas de tratamiento de agua potable (PTAP), Tratamiento de agua, Red neuronal artificial (RNA).	Tipo de documento	→ Artículo, Tesis
Área temática	→	ingeniería, Sanearniento, informática, matemática	Idioma	→ Inglés, español

Solo se seleccionan los artículos relacionados mediante el análisis de las palabras clave y los resúmenes de cada artículo.

Nota: Adaptado de [4]

De los artículos revisados y mediante una selección se consideran finalmente los artículos que abordan temas acerca del uso de inteligencia artificial (IA) e Internet de las Cosas (IoT) en el tratamiento o potabilización del agua, así como todo aquello que esté relacionado con temas afines. Otra consideración en la selección de los artículos fue en lo tratable a los antecedentes de los distintos métodos de la IA, IoT y el tratamiento de agua. En última instancia, se organizó la información recopilada en relación con los métodos o técnicas empleadas, así como los resultados obtenidos de fuentes bibliográficas revisadas. Esto nos permitió formular una metodología para desarrollar un sistema inteligente basado en IA e IoT, focalizado en el monitoreo, predicción, control u optimización de una planta de tratamiento de agua potable.

III. RESULTADOS

A. Metodología y Técnicas de la Inteligencia Artificial con aplicación a la Predicción de Datos de Calidad y Demanda del Agua

Las técnicas de IA empleadas en la predicción del índice de calidad de agua son las redes neuronales, los sistemas de lógica difusa, aprendizaje automático y máquina de vectores, esto según [5], [30], [31]. Estas técnicas analizan los parámetros de pH, turbidez, temperatura, oxígeno disuelto, conductividad eléctrica y cloro residual libre, en conjunto con eventos de contaminación que puedan afectarlas. Cada una de esas técnicas cuentan con sus propias virtudes según su uso. La técnica de aprendizaje automático facilita la captura de datos y el estudio de cuerpos de agua en lugares remotos, las redes neuronales poseen 36% de eficiencia (en cuanto a la aplicabilidad de técnicas de predicción de calidad de agua), las máquinas de vectores de soporte (MVS) 24%, los sistemas de inferencia neurodifusa (ANFIS) 16% y otras técnicas 24% esto según [30]. La técnica de lógica difusa, tal como indica [32], La lógica difusa, según [32], se utiliza en la detección de contaminación del agua, analizando parámetros como pH, temperatura, oxígeno disuelto, conductividad eléctrica y cloro residual libre. Además, combinando lógica difusa, redes neuronales tipo perceptrón y umbrales dinámicos, es posible detectar y predecir eventos de contaminación que puedan afectar la calidad del agua, es decir, el empleo de técnicas de manera combinada ofrece el poder llegar a resultados más precisos. El uso de inferencia neuro difusa adaptativa (ANFIS) y algoritmos de redes neuronales de retroalimentación (FFNN) en conjunto con un modelo de k-vecinos más cercanos (KNN) logran predicciones con una precisión de hasta el 100%, tal como señala [31]. En Corea del Sur lograron integrar la técnica de mapas autoorganizados (SOM) con la técnica ANFIS para tener una predicción global de los índices de calidad de agua, según lo indicado en [5].

En cuanto a la predicción de la demanda de agua, el uso del método de redes neuronales ha demostrado mejores resultados de predicción en comparación con los métodos tradicionales utilizados por la Empresa Epsel de Lambayeque, como se puede apreciar en la investigación de [33]. Estos modelos de redes neuronales logran acercarse de manera más precisa a los valores reales de consumo de agua, lo cual contribuye a una mejor planificación y gestión del suministro del servicio. Según lo indicado en [34] se respalda esta afirmación al investigar la capacidad de las redes neuronales artificiales para predecir la demanda de agua producida. Este estudio concluye que las redes diseñadas con datos de frecuencia mensual obtienen los mejores resultados (1.83% de error promedio en la predicción) en comparación a las redes diseñadas con datos de frecuencia diaria (2.35%) y de datos diarios filtrados (3.84%). En [35] se complementa estas investigaciones al aplicar diversas técnicas de inteligencia artificial, entre ellas las redes neuronales artificiales, para pronosticar la demanda de agua potable en La Portada. Los resultados indican que el modelo de redes neuronales artificiales fue la opción más adecuada para el comportamiento

de la serie temporal, con métricas de error como MAE, RMSE y MAPE arrojando valores favorables, dichos resultados se justifican en los siguientes errores cuadráticos RMSE: Redes neuronales (0.5464), máquinas de soporte vectorial MVS (17.4429) y Random Forest (48.5493).

Así también se menciona en [10] que la técnica Árbol de decisión en Inteligencia Artificial, desarrollado en base a un Data Set de la plataforma Water Quality, no se puede considerar un gran modelo predictivo. Esto se debe a que la base de datos empleada tenía vacíos que tuvieron que descartar.

TABLA 4
ESTUDIOS DE APLICACIÓN DE IA PARA LA PREDICCIÓN DE DATOS DE CALIDAD DEL AGUA

Predicción de datos de calidad del agua				
Autor	Técnica	Metodología	VARIABLES	Resultados
[30]	- Redes Neuronales - Sistemas de inferencia neurodifusa - Máquinas de vectores de soporte	Revisión sistemática de técnicas de aprendizaje automático aplicables a la predicción de calidad de agua potable	- Redes Neuronales - Sistemas de inferencia neurodifusa - Máquinas de vectores de soporte	Aplicabilidad de técnicas: - Redes Neuronales (36%) - MVS (24%) - Anfis (16%) - Otras técnicas (24%)
[31]	- Sistema de inferencia neurodifusa adaptativa - La red neuronal de retroalimentación	Desarrollo de algoritmo usando ANFIS para predecir el índice de calidad del agua y aplicación de FFNN para clasificar calidad del agua	- Oxígeno disuelto (DO) - pH - Conductividad - Demanda Biológica de Oxígeno - Nitrato - Coliformes fecales y totales	Confiabilidad de índice de calidad del agua: ANFIS (96.17%) Precisión de clasificación de calidad del agua: FFNN (100%)
[36]	- Lógica difusa - Redes neuronales tipo perceptron - Método de umbrales dinámicos	Construcción de un índice de calidad de agua para detectar eventos de contaminación de agua potable (Lógica difusa)	- pH - Temperatura - Turbidez - Oxígeno disuelto - Conductividad eléctrica - Cloro residual libre	Modelo de lógica difusa detecta eventos de contaminación de agua. Sistema de detección y predicción en base a lógica difusa, redes neuronales y método de umbrales dinámicos. No Se Especifica Porcentajes De Confiabilidad

TABLA 5
ESTUDIOS DE APLICACIÓN DE IA PARA LA PREDICCIÓN DE DATOS DE DEMANDA DEL AGUA

Predicción de datos de demanda del agua			
Autor	Técnica	Metodología	Resultados
[33]	Redes Neuronales	Modelo de redes neuronales artificiales construido con MATLAB y entrenado con data real capaz de pronosticar la demanda de agua potable.	Modelo de redes neuronales es más próximo a consumos reales que los métodos tradicionales usados por la empresa. No se especifica porcentaje de proximidad
[35]	- Redes Neuronales - Máquinas de Soporte Vectorial	Aplicación de las técnicas de pronóstico con software RStudio, se determinará cual es el	Raíz del error cuadrático medio RMSAE: - Redes Neuronales (0.5464) Más confiable

	- Random Forest - Algoritmo KNN	mejor modelo en base a data set real.	- Máquinas de Soporte Vectorial (17.4429) - Random Forest (48.5493) Menos confiable - Algoritmo KNN (11.5244)
[34]	Redes Neuronales	Análisis de capacidad de redes neuronales artificiales (de 3 tipos, la primera realiza predicciones diarias, la 2da mensuales y la 3ra diarios filtrados) para predecir la demanda de agua demandada.	Errores promedio de predicción de redes neuronales: - Red neuronal modelo diario (2.35%) - Red neuronal modelo diario filtrados (3.84%) - Red neuronal modelo mensual (1.83%) Más confiable

B. Metodología y Técnicas de la Inteligencia Artificial con Aplicación a la Optimización de Procesos de Tratamiento de Agua Potable

En [8] se determinó que las técnicas cuyos modelos son híbridos (combinación de 2 o más técnicas) arrojan mejores resultados en el proceso de potabilización del agua, pues cubren las desventajas de algunas técnicas y aportan mejoras con la incorporación de estas.

Al optimizar el rendimiento de las plantas de tratamiento de agua, el objetivo principal es mejorar la eficiencia operativa de la planta, maximizando la calidad del agua tratada y minimizando los costos y el consumo de energía, tal como indica [37]. En este sentido, en [38] realizaron un estudio comparativo entre métodos tradicionales y algoritmos genéticos en diseño de redes de agua, encontrando que los algoritmos genéticos superaron a los métodos previamente usados. Esta metodología influyó en el diseño de redes de distribución de agua, logrando diámetros optimizados y mayor confiabilidad, precisión y menor probabilidad de fallas. Esto respalda la aplicación de la inteligencia artificial en plantas de tratamiento de agua para mejorar su eficiencia y rendimiento.

En acuicultura, el uso de técnicas computacionales como el aprendizaje automático resulta útil para optimizar parámetros clave como oxígeno y temperatura en relación con el cultivo y enfermedades. tal como indica [7]. Además, en situaciones en las que la turbidez del agua varía considerablemente debido a las precipitaciones, se ha demostrado que es posible optimizar la dosificación de coagulante Al_2SO_4 . Según se explica en [39], se utilizó una red neuronal entrenada durante 11 meses para encontrar la dosificación óptima, logrando un margen de error máximo del 1.6% en la dosificación adecuada.

En la producción de agua potable se busca obtener un beneficio económico al utilizar la cantidad óptima de coagulante a través del análisis de muestras durante varios meses, realizando pruebas de Jarras, según [40]. Estos resultados se validan mediante el uso de algoritmos genéticos, que presentan un margen de error de aproximadamente 0.8%. Esta estrategia garantiza una dosificación precisa y eficiente del coagulante en el proceso de producción de agua potable (99.2%), optimizando así los recursos y los costos asociados.

TABLA 6
ESTUDIOS DE APLICACIÓN DE IA PARA LA MEJORA DE LA EFICIENCIA EN LA OPTIMIZACIÓN DE PROCESOS DE TRATAMIENTO.

Mejora de eficiencia				
Autor	Técnicas	Variables	Descripción	Resultados / Eficacia
[37]	Algoritmos genéticos	pH, arsénico	Basado en algoritmos genéticos, el objetivo es optimizar el rendimiento de las plantas de tratamiento de agua	Mejoras significativas en la eficiencia de planta (calidad de agua, costos y consumo de energía)
[40]	RN	pH, turbidez, conductividad, color	Debido al problemas de las precipitaciones que causan turbidez, se trata de optimizar la cantidad de coagulante entrenando redes neuronales	En su entrenamiento obtuvo un 98.4% para predecir la dosificación del coagulante óptimo.
[39]	Algoritmos genéticos	pH, turbidez, temperatura, color	Uso de algoritmos genéticos para la optimización de la dosificación del coagulante (sulfato de aluminio) para un mejor rendimiento en la empresas públicas o privadas productoras de agua potable.	99.2%, error de 0.08%

TABLA 7
ESTUDIOS DE APLICACIÓN DE IA PARA LA MEJORA DEL TRATAMIENTO Y CALIDAD EN LA OPTIMIZACIÓN DE PROCESOS DE TRATAMIENTO.

Mejora de tratamientos y calidad			
Autor	Técnicas	Metodología	Resultados
[7]	Aprendizaje automático	Muestreo de distintos aprendizajes automáticos para su aplicación en la acuicultura	Se optimizan los parámetros como el oxígeno y temperatura.
[38]	Algoritmos genéticos	Comparaciones entre un diseño de redes de distribución clásico con la inteligencia artificial donde se precisa los cálculos y se optimizan.	Facilita significativamente el diseño de redes de distribución, así como obtener diámetros optimizados con un mayor porcentaje, confiabilidad y precisión.
[8]	Modelos de predicción híbrido	Mapeo sistemático sobre la predicción del agua y se explica las técnicas con mayores resultados	La construcción de modelos híbridos fue el tema con mayor enfoque (46.1%), primordialmente para cubrir desventajas y aportar mejoras.

C. Metodología y Técnicas de la Inteligencia Artificial en el Control de Parámetros de Calidad del Agua

Se han explorado metodologías basadas en inteligencia artificial y tecnologías de monitoreo para mejorar la calidad del agua en plantas de tratamiento. Estas incluyen el uso de lógica difusa y sensores para ajustar los niveles de arsénico, redes neuronales para controlar la turbidez y dosificar coagulantes, y herramientas de inteligencia artificial para identificar y clasificar contaminantes.

Ejemplo, se empleó el método de lógica difusa y sensores para monitorear y ajustar automáticamente la cantidad de arsénico en plantas de tratamiento de agua potable [41]. Los resultados obtenidos mostraron una eficacia del 100%, con concentraciones inferiores a los límites establecidos por la OMS (6.66 µg/L para arseniato y 1.02 µg/L para arsenito), utilizando dosis de Fe (VI) y Fe (III).

Además, se utiliza un modelo de redes neuronales, como indica [42], para controlar variables como la turbidez mediante el uso de coagulantes en el tratamiento de agua potable. En un estudio específico relacionado con la efluencia del alcantarillado en industrias de curtido, se dosificó de manera óptima el policloruro de aluminio para reducir contaminantes como la demanda bioquímica de oxígeno (DBO5), demanda química de oxígeno (DQO) y los sólidos suspendidos totales (SST). Los resultados demostraron una reducción del 70% en los contaminantes, con valores de DBO5 de 211.3 mg/L de O2, DQO de 790 mg/L y SST de 109.7 mg/L, mediante la dosificación adecuada de coagulantes.

El entrenamiento de una red neuronal GRN durante aproximadamente 11 meses, analizando variables como turbidez, pH, conductividad, color y sólidos disueltos, permite encontrar la dosificación óptima de Al2SO4 y mantener así el nivel de turbidez y la calidad del agua bajo control. Los factores más influyentes fueron los sólidos disueltos (42.79%), la turbidez (32.43%), la conductividad (10.33%), el pH (7.26%) y el color (7.19%). Estos factores, según su variabilidad y desviación estándar, impactan en el ingreso del agua a la planta. Como resultado, se obtuvo una eficiencia del 97.77% y un error del 2.23% en el proceso de control mediante red neuronal GRN, esto según [43].

En [9], se destacó el uso de la herramienta de IA "Lobe" de Microsoft para identificar y clasificar contaminantes en el agua, lo que facilita la creación de sistemas de control. De 104 muestras, solo 6 fueron clasificadas incorrectamente, lo que sugiere una alta precisión en la identificación de categorías de agua como potable, sólidos, aceite o turbia. Esto resultó en una exactitud del 94.2% y un error del 5.8% en la clasificación de las muestras de agua utilizando la herramienta de Inteligencia Artificial.

TABLA 8
RESULTADOS DE MÉTODOS DE INTELIGENCIA ARTIFICIAL EN EL CONTROL DE PARÁMETROS DE CALIDAD DE AGUA

Autor	Método	Resultados		
		Variables	Valores	Eficacia
[41]	Lógica Difusa	Arseniato	6,66 µg/	<10 µg/L con Fe (VIy III) (100% eficaz)
		Arsenito	1,01 µg/L	
[42]	Redes Neuronales	DBO5	211.3 O2 mg/L	70% de reducción con el policloruro de aluminio
		DQO	790 mg/L	
		SST	109.7 mg/L	
[43]	Redes Neuronales	Sólidos Disueltos	42.79%	97.77% de efectividad 2.23% de error
		Turbidez	32.43%	
		Conductividad	10.33%	
		pH	7.26%	
[9]	Herramienta de inteligencia	Agua Potable	De 104 muestras, 6	94.2% de exactitud 5.8% de error
		Sólidos		
		Aceite		

	artificial de Microsoft Lobe	Turbia	fueron erróneas	
--	------------------------------	--------	-----------------	--

En la Tabla 8 se destaca el uso de diferentes técnicas de inteligencia artificial y sistemas de control para mejorar la calidad del agua en plantas de tratamiento. La lógica difusa y sensores ajustaron los niveles de arsénico en el agua potable, cumpliendo los estándares de la OMS. Las redes neuronales también redujeron la turbidez en el agua industrial con eficacia. El entrenamiento prolongado mantuvo la calidad del agua bajo control y detectó factores clave. Además, una herramienta de inteligencia artificial logró una clasificación precisa de contaminantes. En resumen, estas técnicas ofrecen soluciones prometedoras para mejorar la calidad y potabilidad del agua.

IV. DISCUSIÓN

Se propone un flujograma para un sistema inteligente en una planta de tratamiento de agua potable, basado en las técnicas de IA e IoT que demostraron mejores resultados en nuestra investigación.

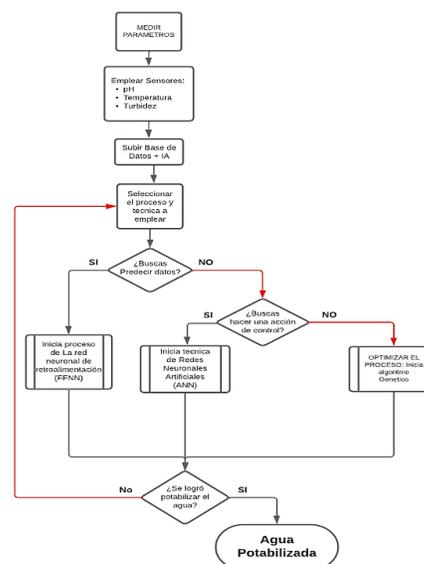


Fig. 2 Flujograma

Nota: Elaboración propia

En este flujograma representaremos el proceso por el cual realizaremos la potabilización del agua siguiendo una secuencia de pasos. Comenzamos con la medición de ciertos parámetros para la potabilización del agua, de los cuales escogimos los más relevantes según los artículos estudiados: pH, temperatura y turbidez.

Ahora bien, los símbolos que representaremos son: el rectángulo, acciones del proceso; el rombo, que representan las interrogantes respecto a una bifurcación en el proceso donde se toma una decisión; los rectángulos secundarios (que son los que tienen como doble raya en sus laterales), donde se pondrá el tipo de técnica de la IA para obtener lo que buscamos; y por último tenemos a la elipse, que viene a ser que todo el proceso se llevó a cabo correctamente y se potabilizó el agua.

Por otro lado, las flechas con color negro representan el sí y la continuidad del proceso en sentido progresivo, las flechas

del color rojo representan el no y la formulación de una nueva interrogante o reinicio del proceso.

El flujograma concluye cuando la técnica seleccionada logra la potabilización del agua. En caso contrario, se vuelve al proceso de selección de técnicas para lograr la potabilización.

A. Red Neuronal de Retroalimentación (FFNN)

Para esta técnica explicaremos su funcionamiento de manera sencilla para saber cómo es que se desarrolla una vez ingresado nuestros datos:

- Estructura: Una FFNN consta de capas de neuronas organizadas en forma de secuencia lineal. Hay una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona en una capa está conectada a todas las neuronas de la capa siguiente, pero no hay conexiones entre las neuronas de una misma capa ni realimentación.

- Propagación hacia adelante: La información fluye desde la capa de entrada hacia las capas ocultas y, finalmente, hacia la capa de salida. Cada neurona en una capa oculta o en la capa de salida recibe entradas ponderadas de las neuronas de la capa anterior. Luego, aplica una función de activación a la suma ponderada de las entradas para producir una salida.

- Funciones de activación: Las funciones de activación introducidas no linealidad en la red, permitiendo que esta aprenda patrones y relaciones complejas. Algunas funciones de activación comunes son la función sigmoide, la función ReLU (Rectified Linear Unit) y la función tangente hiperbólica.

- Aprendizaje: El proceso de aprendizaje de una FFNN se realiza mediante un algoritmo llamado "retropropagación del error". En resumen, se compara la salida de la red con el valor deseado y se calcula un error. Luego, este error se propaga hacia atrás a través de la red, ajustando los pesos de las conexiones mediante técnicas de optimización como el descenso del gradiente, con el objetivo de minimizar el error.

- Aplicaciones: Las FFNN se utilizan en una amplia gama de aplicaciones, sin embargo, entre nuestro caso lo estamos aplicando para lo que viene a ser el de predecir datos.

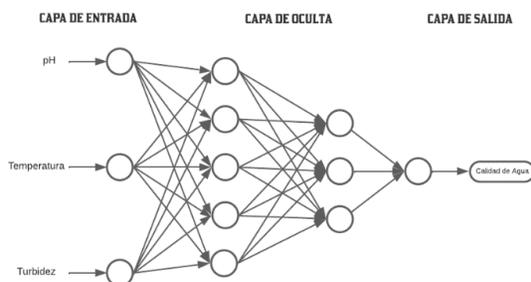


Fig. 3 Proceso de Red de Retroalimentación (FFNN)
Nota: Elaboración propia

B. Red Neuronales Artificiales (ANN)

Para esta técnica explicaremos su funcionamiento de manera sencilla para saber cómo es que se desarrolla una vez ingresado nuestros datos:

- Estructura: Una ANN está compuesta por unidades de procesamiento (neuronas artificiales), organizadas en capas. Normalmente hay una capa de entrada, una o varias capas ocultas y una capa de salida.

- Conexiones ponderadas: Cada neurona está conectada a otras neuronas a través de conexiones ponderadas. Cada conexión tiene un peso que determina su importancia en la transmisión de la información.

- Propagación hacia adelante: La información fluye desde la capa de entrada hacia las capas ocultas y finalmente hacia la capa de salida. Cada neurona en una capa recibe entradas ponderadas de las neuronas de la capa anterior y aplica una función de activación para producir una salida.

- Funciones de activación: Las funciones de activación introducidas no linealidad en la red, permitiendo que esta aprenda y modele relaciones complejas en los datos de entrada. Algunas funciones de activación comunes son la función sigmoide, la función ReLU y la función tangente hiperbólica.

- Aprendizaje: Las ANN aprenden a través de un proceso llamado "entrenamiento". Durante el entrenamiento, la red se expone a ejemplos de entrada junto con las salidas deseadas. Los pesos de las conexiones se ajustan gradualmente mediante algoritmos de aprendizaje, como el descenso del gradiente, con el objetivo de minimizar la diferencia entre las salidas de la red y las salidas deseadas.

- Generalización: Una vez entrenada, la red puede generalizar y producir salidas razonables para nuevas entradas que no se vieron durante el entrenamiento. En nuestro caso, lo estaremos empleando para realizar una acción de control.

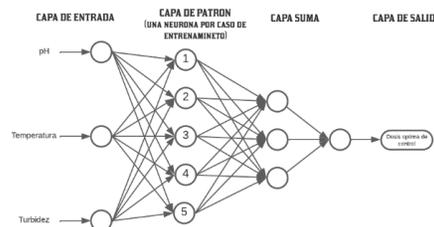


Fig. 4 Proceso de Redes Neuronales Artificiales
Nota: Elaboración propia

C. Algoritmo Genético

Para esta técnica explicaremos su funcionamiento de manera sencilla para saber cómo es que se desarrolla una vez ingresado nuestros datos:

- **Población inicial:** Comienza con una población inicial de individuos. Cada individuo representa una posible solución al problema que se quiere resolver.

- **Evaluación de la aptitud:** Cada individuo se evalúa en función de su aptitud, que es una medida de qué tan buena es su solución en relación con el objetivo del problema. Los individuos más aptos tienen más probabilidad de sobrevivir y reproducirse.

- **Selección:** Se seleccionarán los individuos más aptos para reproducirse y crear una descendencia. Hay varias estrategias de selección, como la selección por ruleta, donde los individuos más aptos tienen una mayor probabilidad de ser seleccionados.

- **Operadores genéticos:** Se aplican operadores genéticos a la descendencia para simular la reproducción biológica. Los operadores principales son la cruce y la mutación. En la cruce, se combinan características de dos individuos seleccionados y se crea un nuevo individuo. En la mutación, se introduce una pequeña modificación aleatoria en el material genético del individuo.

- **Nueva generación:** La descendencia y, posiblemente, algunos individuos de la generación anterior forman la nueva generación. Este proceso se repite durante varias generaciones.

- **Convergencia y solución:** Con el paso del tiempo, la población tiende a mejorar en términos de aptitud. Eventualmente, puede converger hacia una solución óptima o satisfactoria para el problema planteado.

El Algoritmo Genético será considerado para la optimización de los procesos en la potabilización del agua.

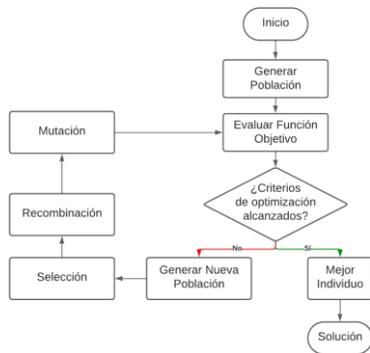


Fig. 5 Proceso de Algoritmo Genético
Nota: Elaboración propia

V. CONCLUSIONES

Concluimos del análisis de los parámetros que se emplean en el control de la calidad del agua, así como del monitoreo del tratamiento de esta, que el pH, la turbidez y la temperatura son los que mayormente se emplean al momento de utilizar sensores, IoT e IA para la recolección de datos. Esto debido a la mayor existencia de sensores de este tipo. Además, estos parámetros permiten detectar de manera rápida las alteraciones

que el agua tuviera en su calidad. En cuanto a las técnicas de Inteligencia Artificial usadas para la predicción de calidad del agua, se tiene que el modelo con mayor aplicabilidad es el que aplica la técnica de Redes Neuronales, sin embargo, también es recomendable el uso de técnicas combinadas (uso conjunto de inferencia neuro difusa adaptativa, algoritmos de redes neuronales de retroalimentación, y otras técnicas) para poder obtener resultados favorables. Por otra parte, las Redes Neuronales también son la mejor técnica para la predicción de demanda del agua, ya que los modelos que se desarrollan en base a esta técnica logran aproximarse más a la realidad en comparación a técnicas tradicionales, y se recomienda que el análisis realizado por dichas redes sea de forma mensual para obtener mayor precisión en la predicción.

En la inteligencia artificial aplicada a la optimización de procesos de tratamiento de agua potable, se busca mejorar el rendimiento de la planta, aumentar la eficiencia operativa y maximizar la calidad del agua tratada mientras se reducen costos y consumo de energía. Esto se logra mediante el uso de algoritmos genéticos y redes neuronales para determinar la cantidad precisa de coagulante necesario durante varios meses, lo que resulta en beneficios económicos.

El uso de técnicas avanzadas como la lógica difusa, redes neuronales y herramientas de Inteligencia Artificial ha demostrado una eficacia del 100% en el monitoreo y control de la calidad del agua, con resultados que cumplen los estándares establecidos por la OMS. Estas técnicas permiten ajustar automáticamente la cantidad de arsénico, controlar la turbidez y reducir contaminantes, mejorando así la eficiencia y la calidad del agua en plantas de tratamiento. Se recomienda seguir explorando y aplicando estas tecnologías para garantizar un suministro de agua potable seguro y de alta calidad.

Se propuso un flujograma como resultado final del presente artículo. El objeto final es detallar el proceso adecuado para lograr la potabilización del agua. El flujograma fue elaborado de tal manera que en una PTAP se pueda escoger una de las tres acciones: predecir, optimizar y controlar. Y si requiere más de una acción se reitera el proceso. Cada acción escogida emplea las técnicas y/o métodos de mayor eficacia ya determinados en la parte

REFERENCIAS

- [1] Instituto Geofísico del Perú, “IGP recuerda la importancia del agua - Noticias - Instituto Geofísico del Perú - Plataforma del Estado Peruano”, Unidad Funcional de Comunicaciones. Consultado: el 1 de junio de 2023. [En línea]. Disponible en: <https://www.gob.pe/institucion/igp/noticias/593963-igp-recuerda-la-importancia-del-agua>
- [2] Organización Mundial de la Salud (OMS), “Agua para consumo humano”, Centro de Prensa. Consultado: el 31 de mayo de 2023. [En línea]. Disponible en: <https://www.who.int/es/news-room/fact-sheets/detail/drinking-water>
- [3] J. Suquet *et al.*, “Development of an environmental decision support system for enhanced coagulation in drinking water production”, *Water (Switzerland)*, vol. 12, núm. 8, ago. 2020, doi: 10.3390/W12082115.

- [4] A. G. Olabi *et al.*, “Application of artificial intelligence for prediction, optimization, and control of thermal energy storage systems”, *Thermal Science and Engineering Progress*, p. 101730, mar. 2023, doi: 10.1016/j.tsep.2023.101730.
- [5] K. J. Lee, S. T. Yun, S. Yu, K. H. Kim, J. H. Lee, y S. H. Lee, “The combined use of self-organizing map technique and fuzzy c-means clustering to evaluate urban groundwater quality in Seoul metropolitan city, South Korea”, *J Hydrol (Amst)*, vol. 569, pp. 685–697, feb. 2019, doi: 10.1016/j.jhydrol.2018.12.031.
- [6] S. Azimi, M. Azhdary Moghaddam, y S. Hashemi Monfared, “Prediction of annual drinking water quality reduction based on Groundwater Resource Index using the artificial neural network and fuzzy clustering”, *J Contam Hydrol*, vol. 220, pp. 6–17, ene. 2019, doi: 10.1016/j.jconhyd.2018.10.010.
- [7] W. Vásquez-Quispesivana, M. Inga, y I. Betalalleluz-Pallardel, “Artificial intelligence in aquaculture: basis, applications, and future perspectives”, *Scientia Agropecuaria*, vol. 13, núm. 1. Universidad Nacional de Trujillo, pp. 79–96, 2022. doi: 10.17268/SCI.AGROPECU.2022.008.
- [8] I. D. López, A. Figueroa, y J. C. Corrales, “Un mapeo sistemático sobre predicción de calidad del agua mediante técnicas de inteligencia computacional”, *Revista Ingenierías Universidad de Medellín*, vol. 15, núm. 28, pp. 35–52, 2016, doi: 10.22395/rium.v15n28a2.
- [9] C. A. Ramirez, “Desarrollo de un sistema clasificador de contaminantes en una muestra de agua utilizando inteligencia artificial”, *Universidad Politécnica Salesiana*, 2022.
- [10] A. Alexis *et al.*, “Modelo predictivo de la potabilidad del agua mediante un árbol de decisión en Inteligencia Artificial Predictive model of water potability through a decision tree in Artificial Intelligence”, *Revista Innovación y Software*, vol. 3, núm. 2, 2022.
- [11] Y. Salinas, D. Galván, I. Guzmán, y J. Orrante, “El impacto del internet de todas las cosas (IoT) en la vida cotidiana”, *Ciencia Latina Revista Científica Multidisciplinar*, vol. 6, núm. 2, pp. 1369–1378, abr. 2022, doi: 10.37811/cl_rm.v6i2.1959.
- [12] M. Márquez, M. Sánchez, A. Mejías, y J. Andújar, “Las ventajas del IoT en el diseño de laboratorios remotos: myGATEWAY”, *Universidade da Coruna*, ago. 2019, pp. 294–301. doi: 10.17979/spudc.9788497497169.294.
- [13] A. Trotti, “Descripción y análisis de las ventajas y desafíos para la adopción de soluciones de Industrial Internet of Things en Vaca Muerta”, may 2021.
- [14] J. C. León Pérez, “Impacto de las tecnologías disruptivas en la percepción remota: big data, Internet de las Cosas e inteligencia artificial”, 2019.
- [15] L. F. Loyola y G. M. Zarate, “Diagnóstico del sistema de abastecimiento de agua potable de agua potable en el Centro Poblado de Marcapampa, distrito Demacate, departamento Ancash y su incidencia en la condición sanitaria de la población - 2019”, 2019.
- [16] Dirección General de Salud Ambiental - Minsa, *Reglamento de la calidad de Agua para Consumo Humano*, vol. 1. 2011.
- [17] M. Romero, “Tratamientos utilizados en potabilización de agua”, 2008.
- [18] E. Mamani *et al.*, “Ph del agua potable que consumen estudiantes del segundo año de la carrera de Medicina, Universidad Mayos de San Andres Gestion 2017”, oct. 2017.
- [19] J. Rey y L. Pinilla, “Diseño de una planta de tratamiento de agua potable en el Municipio de Rio Sucio - Chocó”, 2020.
- [20] J. Teves y M. Illesca, “Proceso de neutralización con soda caustica como un método alternativo de tratamiento de aguas acidas para incrementar la calidad de agua en la Compañía Minera Cascaminas S.A.”, 2009.
- [21] N. L. Sigúí Gil, “Aspectos a considerar en la cloración de aguas residuales”, 2022.
- [22] B. Christiansen, “4 Keys To Adopting Industry 40 At Your Water Processing Facility”, 2022.
- [23] M. de los Á. Zepeda Hernández y F. F. Franco Pérez, “Red de sensores inalámbricos de adquisición de datos aplicado a una estación de tratamiento de agua potable.”, 2009.
- [24] M. J. Vásquez Bermúdez, J. W. Hidalgo Larrea, J. O. Salavarría Melo, y M. Carchi, “Monitoreo IoT en un Sistema Aeropónico para el cultivo de la Lechuga Orgánica”, *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, vol. 4, núm. 2, may 2023, doi: 10.56712/latam.v4i2.618.
- [25] M. Gonzales, “Prototipo de solución para monitoreo y control remoto de una red de distribución de agua potable usando la tecnología LoRa WAN”, 2022.
- [26] A. Conejeros, C. Hueichaqueo, B. Martínez, y A. Placeres, “Monitoreo de calidad del agua en sistema de agua potable rural”, 2021.
- [27] I. Toledo Trujillo, “Monitoreo de datos de una Estación de Tratamiento de Agua Potable via Internet”, 2010.
- [28] J. D. Pérez Sánchez, “Validación de las técnicas analíticas de la alcalinidad, cloruros y pH de la EAAM-ESP”, 2018.
- [29] Ministerio del Ambiente - MINAM, *Límites Máximos Permisibles para los efluentes de Plantas de Tratamiento de Aguas Residuales Domésticas o Municipales*. 2010, pp. 415675–415676.
- [30] A. C. Aguilar y F. F. Obando - Diaz, “Aprendizaje automático para la predicción de calidad de agua potable”, *Ingeniare*, núm. 28, pp. 47–62, may 2020, doi: 10.18041/1909-2458/ingeniare.28.6215.
- [31] M. H. Al-Adhaileh y F. W. Alsaade, “Modelling and prediction of water quality by using artificial intelligence”, *Sustainability (Switzerland)*, vol. 13, núm. 8, abr. 2021, doi: 10.3390/su13084259.
- [32] F. Andrés Siles, “Desarrollo de software y diseño de un sistema automatizado para monitoreo y predicción de eventos de contaminación en sistema de distribución de agua, utilizando inteligencia artificial”, 2015.
- [33] A. V. Siadén Yasmín, “Aplicación de las redes neuronales para el pronóstico de la demanda de agua potable en la empresa Epsel S.A. de la ciudad de Lambayeque”, 2012.
- [34] N. Rodríguez Aedo, “Pronóstico de demanda de agua potable mediante redes neuronales”, 2016.
- [35] E. C. Díaz Enriquez, “Modelo para el pronóstico de la demanda de agua potable aplicando modelos de Inteligencia Artificial en la portada del Cantón Mira”, 2023.
- [36] F. Andrés Siles, “Desarrollo de software y diseño de un sistema automatizado para monitoreo y predicción de eventos de contaminación en sistemas de distribución de agua, utilizando inteligencia artificial”, 2015.
- [37] R. Swan, J. Bridgeman, y M. Sterling, “Optimisation of water treatment works performance using genetic algorithms”, *Journal of Hydroinformatics*, vol. 19, núm. 5, pp. 719–733, sep. 2017, doi: 10.2166/hydro.2017.083.
- [38] H. Salas, H. Quispe, J. Soto, y V. Jurado, “Diseño de redes de distribución de abastecimiento de agua utilizando métodos racionales complejos e inteligencia artificial en Callqui Grande-Huancavelica”, *Revista Científica Ciencias Ingenieriles*, vol. 3, núm. 1, pp. 11–25, ene. 2023, doi: 10.54943/ricci.v3i1.221.
- [39] H. Huamán, S. Arauco, R. Rojas, y J. Rojas, “Optimización de la cantidad de coagulantes para la producción de agua potable en zonas de la sierra del Perú”, *UCV-SCIENTIA*, vol. 12, núm. 1, jun. 2020, doi: 10.18050/revucv-scientia.v12i1.920.
- [40] A. C. Peña Rojas, “Uso de redes neuronales artificiales para optimizar la dosificación de coagulantes en la Planta de Tratamiento de Agua Potable - Huancayo”, 2016.
- [41] F. P. Larroca, E. S. Olschewski, J. Quino-Favero, J. R. Huamani, y J. L. C. Sequera, “Water treatment plant prototype with ph control modeled on fuzzy logic for removing arsenic using fe(Vi) and fe(iii)”, *Water (Switzerland)*, vol. 12, núm. 10, oct. 2020, doi: 10.3390/w12102834.
- [42] M. O. García La Barrera, B. J. C. Vega Gonzales, J. C. Mariños Legendre, B. B. Anhuaman Namoc, M. Campos Gutiérrez, y M. E. Pinglo Bazán, “Redes neuronales artificiales para el tratamiento de efluentes de curtiduría”, *Revista de Innovación y Transferencia Productiva - RITP*, vol. 2, núm. 2, p. e002, feb. 2022, doi: 10.54353/ritp.v2i2.e002.
- [43] A. Peña Rojas y L. Flores del Pino, “Redes neuronales para el tratamiento de agua potable en zona de altitud del Perú”, *Ambiente y Desarrollo*, vol. 18, núm. 35, p. 108, jul. 2014, doi: 10.11144/javeriana.ayd18-35.rnta.