

# Ciencias e Ingeniería

PARA CIUDADANOS

Revista de investigación científica



Lima - Perú

# Ciencias e Ingeniería



Volumen II-N°4 Abril 2026

# Consejo Editorial

## Director

Dr. Francisco Javier Wong Cabanillas

## Editor, diseño y traducción

Lic. Carlos Alberto Vega Vidal

## Diagramador de texto y asistencia de diseño

Lic. Carlos Alberto Vega Vidal

## Comité Científico

Dra. Elena Rafaela Benavides Rivera  
Universidad Nacional Mayor de San Marcos.  
Lima-Perú

Dra. Ysabel Zevallos Parave  
Universidad Nacional de Educación Enrique Guzmán y Valle.  
Lima-Perú

Dr. Óscar Rafael Tinoco Gómez  
Universidad Nacional Mayor de San Marcos.  
Lima-Perú

# Implementación de la inteligencia artificial basada en machine learning para la mejora del desempeño de sistemas de tratamiento de aguas residuales

Sr. Walter Jesús Soria Tadeo  
Universidad Nacional Mayor de San Marcos  
Correo electrónico: walter.soria@unmsm.edu.pe

Srta. Emily Garro Aponte  
Universidad Nacional Mayor de San Marcos  
Correo electrónico: emily.garro@unmsm.edu.pe

**Resumen:** El presente artículo evalúa el papel de la inteligencia artificial en el uso del machine learning (ML) en la optimización continua del rendimiento en sistemas de tratamiento de aguas residuales (PTAR). En un primer momento, fueron identificados los problemas asociados a la gestión reactiva, caracterizados por los tiempos de espera y por un alto consumo eléctrico, como el proceso de aireación (30-76% del total del costo de energía). En relación con el análisis documental, es posible observar que la implementación del ML permite disminuir la incertidumbre en lo que respecta a los factores biológicos, ya que permite detectar con precisión total (ROC-AUC 1.0) problemas críticos y alertar la posibilidad de fallos de equipo con 2.5 horas de antelación. Al automatizar la gestión a través de la IA, la normativa ambiental se cumple, logrando optimizar la gestión de recursos mediante la reducción de consumo energético en un 49%, obteniendo así ahorros económicos en torno a los \$180,000 anuales. Otro de los beneficios de implementación fue la adaptación a la variabilidad del influente, permitiendo ahorrar el 90% en casos de desbordamientos. Por último, con la utilización de sensores virtuales, es posible predecir los parámetros de calidad con un  $0.96 R^2$ , considerando solamente 10 variables cruciales. Se concluye que el ML, en el marco de la Industria 4.0, permite la transición hacia una gestión predictiva que reemplaza los análisis tradicionales lentos, mejorando drásticamente la resiliencia operativa, la sostenibilidad financiera y el control eficiente de las plantas de tratamiento.

**Palabras clave:** Tratamiento de aguas / Machine learning / IA / Optimización / Gestión predictiva

**Abstract:** This article evaluates the role of artificial intelligence (AI) through machine learning (ML) in the continuous performance optimization of Wastewater Treatment Plants (WWTPs). Initially, issues associated with reactive management were identified, characterized by response delays and high electricity consumption, particularly in the aeration process, which accounts for 30–76% of total energy costs. Based on the literature review, the implementation of ML reduces uncertainty regarding biological factors by accurately detecting critical issues (ROC-AUC 1.0) and providing alerts for potential equipment failures 2.5 hours in advance. By automating management via AI, regulatory compliance is ensured while optimizing resource allocation, resulting in a 49% reduction in energy consumption and annual economic savings of approximately \$180,000.

An additional benefit of this implementation is the adaptation to influent variability, which enables a 90% savings in overflow scenarios. Furthermore, through the use of soft sensors (virtual sensors), it is possible to predict quality parameters with an  $R^2$  of 0.96 using only ten crucial variables. The study concludes that ML, within the framework of Industry 4.0, facilitates the transition toward predictive management, replacing slow traditional analytical methods and drastically improving operational resilience, financial sustainability, and efficient plant control.

**Key words:** Wastewater treatment / Machine learning / AI / Optimization / Predictive management

**Résumé:** Cet article évalue le rôle de l'intelligence artificielle à travers l'utilisation du machine learning (ML) dans l'optimisation continue de la performance des stations d'épuration des eaux usées (STEP). Dans un premier temps, les problèmes associés à la gestion réactive ont été identifiés, caractérisés par des délais d'attente et une consommation électrique élevée, notamment lors du processus d'aération (représentant 30 à 76 % du coût énergétique total). En ce qui concerne l'analyse documentaire, il est possible d'observer que la mise en œuvre du ML permet de réduire l'incertitude liée aux facteurs biologiques, car elle permet de détecter avec une précision totale (ROC-AUC 1,0) des problèmes critiques et d'alerter sur d'éventuelles défaillances d'équipement 2,5 heures à l'avance. En automatisant la gestion grâce à l'IA, la conformité aux normes environnementales est assurée, tout en optimisant la gestion des ressources par une réduction de la consommation d'énergie de 49 %, générant ainsi des économies financières de l'ordre de 180 000 \$ par an. Un autre avantage de cette mise en œuvre est l'adaptation à la variabilité de l'affluent, permettant d'économiser 90 % en cas de débordements. Enfin, grâce à l'utilisation de capteurs virtuels (soft sensors), il est possible de prédire les paramètres de qualité avec un  $R^2$  de 0,96, en ne considérant que 10 variables cruciales. En conclusion, le ML, dans le cadre de l'Industrie 4.0, permet la transition vers une gestion prédictive qui remplace les analyses traditionnelles lentes, améliorant considérablement la résilience opérationnelle, la durabilité financière et le contrôle efficace des usines de traitement.

**Mots-clés:** Traitement des eaux usées / Machine learning / IA / Optimisation / Gestion prédictive

## 1. INTRODUCCION

El machine learning (ML) se define como una de las ramas de la inteligencia artificial (IA) que resuelve problemas mediante la identificación, interpretación y procesamiento de datos; para ello es necesario que las máquinas aprendan de datos reales proporcionados, para ofrecer un método automatizado que pueda reconocer patrones (Regil-Vargas y Sanabria, 2024). Por el momento, la aplicación industrial del ML se concentra principalmente en grandes empresas internacionales. La adopción de esta tecnología se enfrenta al rechazo debido a la preocupación de que pondrá en riesgo a muchos puestos de trabajo. No obstante, diversos estudios señalan que su uso no busca reemplazar al profesional, sino automatizar y ahorrar tiempo en tareas redundantes y repe-

titivas, liberando a los investigadores de prácticas tradicionales que resultan costosas, lentas y propensas a errores (Bertolini et al., 2021).

En contextos donde la demanda del tratamiento eficiente y monitoreo continuo del agua es cada vez mayor, como ocurre en las ciudades en crecimiento y en sectores industriales, resulta fundamental analizar el impacto del uso de ML y los beneficios que conlleva su implementación, además de la optimización del proceso y supervisión en plantas. Durante los últimos años, se evidenció un crecimiento significativo del interés científico en este campo, alcanzando su mayor producción en 2023. Asimismo, se demostró que el ML se ha consolidado como una de las principales líneas de estudio para optimizar la gestión de contaminantes y promover soluciones sostenibles en sistemas de tratamiento de aguas residuales (Alaloul et al., 2024).

A causa de esta relación, surge la siguiente interrogante que nos lleva a realizar nuestro análisis: ¿Cómo influye la implementación de modelos de ML en la mejora continua de sistemas de tratamiento de aguas residuales? Teniendo como tesis de trabajo la siguiente: La implementación de la IA basada en ML influye positivamente en la mejora del desempeño, ya que aporta la detección temprana de anomalías o fallas, versatilidad en el proceso, reducción en tiempo de obtención de datos y la transición hacia la automatización en sistemas de tratamiento de aguas residuales.

Asimismo, tenemos como finalidad concientizar a los profesionales y estudiantes de ingeniería sobre la viabilidad y los beneficios de integrar herramientas de IA en sistemas de tratamiento de aguas. A continuación, desarrollaremos los siguientes temas: Reducción de la incertidumbre operativa, anticipación de incumplimientos normativos, mantenimiento predictivo, adaptabilidad ante variabilidad del influente, optimización energética y reducción de costos operativos, robustez operativa, monitorización de parámetros de calidad en tiempo real, ejecución de acciones correctivas instantáneas, análisis inmediato de resultados y monitoreo de parámetros de manera virtual y económica.

## **2. ARGUMENTO 1**


### **La detección temprana de anomalías o fallas**

Entonces, para entender cómo la implementación de la IA genera mejoras, es fundamental analizar la capacidad de resolver los problemas críticos desde el inicio del proceso y el impacto a la estabilidad que genera al sistema: la detección temprana de anomalías y fallas. Lo que permite reducir drásticamente la incertidumbre de ciertos procesos biológicos y anticipar posibles incumplimientos en la normativa ambiental

La implementación de la IA basada en ML influye positivamente en la mejora del desempeño de las PTAR, ya que aporta la detección temprana de anomalías o fallas, Uno de los problemas que se suelen presentar en las plantas de tratamiento de aguas residuales (PTAR) es el bulking, el cual consiste en que los lodos pierden la capacidad de sedimentar. Al tratarse de un fenómeno biológico, es muy difícil de predecir cuándo

ocurrirá. La tecnología basada en algoritmos de gradient boosting (librería CatBoost), demostró ser la estrategia más eficaz. Superando a los modelos estadísticos clásicos, este enfoque de aprendizaje automático procesó la complejidad de los datos operativos de la planta de tratamiento, logrando predecir la calidad del efluente con un error mínimo (SMAPE 9.1%) y detectar anomalías biológicas críticas (bulking) con exactitud perfecta (ROC-AUC 1.0). (Gulshin y Kuzina, 2024). El uso de aprendizaje automático avanzado permite analizar grandes volúmenes de datos complejos de la planta para anticipar problemas graves en el proceso biológico y medir la calidad del agua con una precisión que los métodos tradicionales no alcanzan. El hallazgo mencionado es fundamental porque elimina la "caja negra" de los procesos biológicos fundamentados en el bulking. Esto transforma la incertidumbre operativa en una variable controlable, permitiendo una gestión basada en datos y no suposiciones. Como se observa en la figura 1, este análisis no se limita a una sola variable, sino que evalúa las interacciones críticas del sistema, tales como la correlación entre la carga orgánica de entrada y salida, así como el impacto directo de la temperatura y el oxígeno disuelto sobre la remoción de nutrientes. Se recomienda la adopción de librerías de gradient boosting en plantas que sufren de inestabilidad biológica frecuente para mitigar paradas no programadas y optimizar la toma de decisiones.

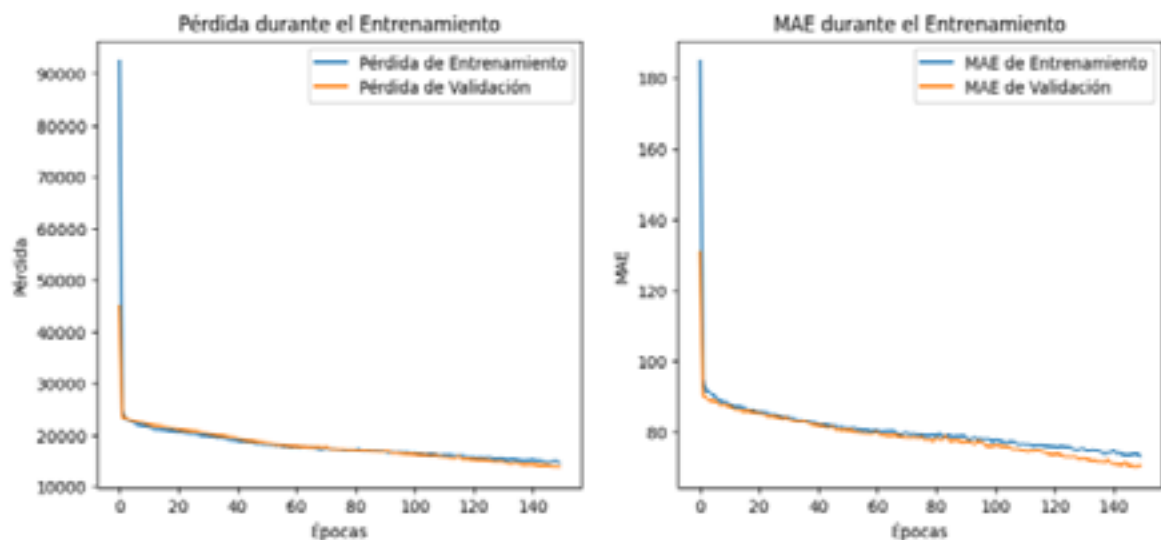
**Figura N° 1:** Diagrama de dispersión de variables



**Fuente:** La figura presenta diagramas de dispersión que evalúan la dependencia lineal entre variables predictoras y objetivos de calidad del efluente: (a) correlación entre la demanda bioquímica de oxígeno (DBO) de entrada y salida; (b) relación entre la temperatura y la concentración de amonio en el efluente; y (c) relación entre el oxígeno disuelto y el amonio en el efluente. Adaptado de "Machine learning methods for the prediction of wastewater treatment efficiency and anomaly classification with Lack of Historical Data" ( p. 14) por I. Gulshin y O. Kuzina, 2024, Applied sciences, 15.

Uno de los desafíos más críticos en la gestión de aguas residuales es la dosificación precisa de reactivos, donde la variabilidad del caudal y la carga contaminante suelen superar la capacidad de respuesta manual. Frente a esta problemática, la automatización inteligente surge como una solución para estandarizar el tratamiento. Se ha desarrollado un algoritmo de IA que moderniza el proceso de dosificación química en aguas residuales, logrando una precisión superior al 90% y una convergencia adecuada en su modelado (Marin, 2024). La implementación del ML actualiza métodos tradicionales mejorando su exactitud y eficacia. La relevancia de esta precisión radica en su impacto directo sobre la conformidad legal y sostenibilidad ambiental. Al modernizar la dosificación, se garantiza que el tratamiento químico sea constante y adecuado a la carga contaminante real, eliminando la subjetividad humana entrenando a la IA (figura 2), logrando patrones de dosificación adecuados sin derroche alguno

**Figura N° 2:** Entrenamiento y validación del modelo propuesto usando datos de entrenamiento y reales

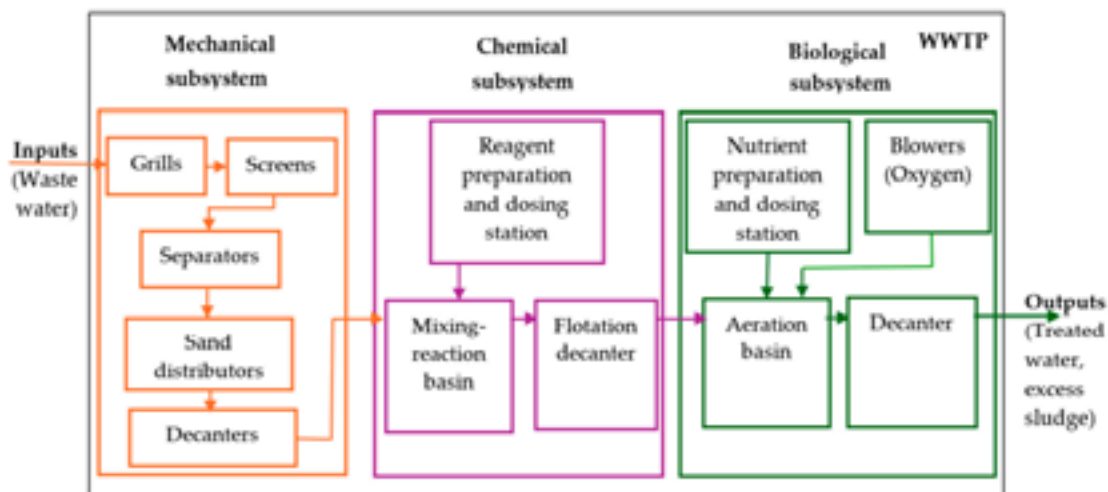


**Fuente:** Se observa la estabilidad del aprendizaje del modelo; el descenso constante en las curvas de pérdida (a) y la estabilización del Error Absoluto Medio (MAE) (b) demuestran que el algoritmo presenta una convergencia adecuada. adaptado de prototipo de modelo de inteligencia artificial para mejorar la dosificación química en el proceso de tratamiento de aguas residuales de la industria textil (p. 30), por Marin, J., 2024, Universidad EAN

Esto hace que la regulación ambiental tome relevancia, utilizando a la IA como un organismo de gestión preventiva. La integración de tecnologías basadas en ML mejora las capacidades de predicción de las PTAR, destacando el cumplimiento de la normativa ambiental, evitando así las sanciones legales y económicas asociadas a la contaminación por descargas fuera de norma (Zamfir et al., 2025). El uso de herramientas de aprendizaje automático permite anticipar cómo será la calidad del agua a la salida de la planta, asegurando su calidad frente al ambiente. Esto funciona como un cambio de paradigma en la administración de la gestión del proceso (figura 3) dentro de las plantas de tratamiento, en donde la inversión tecnológica no solo se justifica en aumento

de eficiencia. Esta se ve tangiblemente en la evasión de sanciones por incumplimiento normativo. Se sugiere utilizar estos modelos predictivos como "auditores virtuales" en tiempo real, configurando alertas automáticas que detengan la descarga si la predicción indica una posible violación normativa en las próximas horas.

**Figura N° 3:** Diagrama de bloques del proceso de tratamiento de aguas residuales




**Fuente:** Adaptado de "Application of machine learning models in optimizing wastewater treatment processes: A review" (p.5), por F. Zamfir, M. Carbureanu & S. Mihalache, 2025, Applied sciences, 15(15).

Llamuca y Bayas (2025) desarrollaron un modelo predictivo basado en técnicas de ML como el Random Forest que, con una precisión alta, automatiza el monitoreo de parámetros críticos según la norma NTE INEN 1108, lo que facilita la anticipación de desviaciones en la calidad del agua y minimiza el riesgo de incumplimiento normativo derivado de errores humanos. Estos autores validaron que algoritmos robustos como el Random Forest pueden vigilar automáticamente que el agua cumpla con estándares específicos, reduciendo drásticamente la posibilidad de fallos causados por equivocaciones. El uso específico de Random Forest en este contexto demuestra que los modelos de ensamble son ideales para manejar las exigencias regulatorias, ya que ofrecen una estabilidad superior frente a datos ruidosos. Al eliminar la dependencia exclusiva del muestreo manual, se cierra la brecha de incertidumbre entre la toma de muestra y el resultado de laboratorio. Aconsejando así la integración de modelos tipo RF integrados a sistemas SCADA para la generación de reportes automatizados y fiables

Tradicionalmente, el mantenimiento en plantas industriales se ha basado en calendarios fijos (preventivo) o en la reparación tras la falla (correctivo), lo que conlleva ineficiencias y paradas no programadas. La integración de una IA permite crear estrategias más dinámicas que optimizan la disponibilidad de la planta. Gracias a la integración de algoritmos de ML para el análisis de datos de sensores, paradas históricas y resultados de inspección, se lograron elaborar estrategias de mantenimiento dinámicas, lo que contribuye a garantizar la continuidad del proceso monitoreado (Tapia et al.,

2024). El aprendizaje automático, al cruzar datos de sensores actuales e historiales de averías, permite reemplazar el mantenimiento rígido por fecha, por intervenciones flexibles basadas en el estado real de la maquinaria. Al tener un mantenimiento dinámico, se eliminan las paradas de planta innecesarias que limitan la producción, asegurando que la planta tenga una operación ininterrumpida, objetivo indispensable porque el tratamiento biológico (figura 3) es algo que no se puede detener en una PTAR. Siendo de vital importancia centralizar los registros de bitácoras de mantenimiento antiguas y digitalizarlos; para entrenar a los modelos de IA para que identifiquen patrones invisibles al ojo humano. Para sistemas de alta criticidad, donde una falla mecánica puede detener todo el proceso de tratamiento, la anticipación temporal se convierte en el recurso más valioso. Frente a esto, un estudio aplicado a sistemas de potencia hidráulica, demostraron que la integración de criterios estadísticos robustos (IQR) con modelos de ML multidimensionales (como One Class SVM y redes neuronales LSTM/CNN) permite identificar desviaciones operativas con una antelación de 2.5 horas antes de que ocurra la falla. Esta ventana de predicción no solo reduce las falsas alarmas en comparación con métodos como Isolation Forest (Fic et al., 2023). La combinación de redes neuronales profundas (como LSTM y CNN) con estadística avanzada permite detectar anomalías sutiles en el funcionamiento de equipos críticos con dos horas y media de anticipación, superando en precisión a los métodos de detección de anomalías convencionales. Esta tecnología destaca por ofrecer tiempo "extra" en un margen de 2.5 horas. Esto permite tomar acciones antes de que algún fallo ocurra, haciendo que se pueda trabajar de una manera más controlada y planificada, transformando una emergencia potencial en una tarea de rutina. Como se ilustra en la Figura 4, para lograr esto es necesaria una arquitectura robusta en la nube que procese continuamente el flujo de datos históricos y en tiempo real

**Figura N° 4:** Ecosistema en la nube para el despliegue de algoritmos con historial (machine learning)



**Fuente:** La figura esquematiza cómo los datos históricos y de sensores se procesan en la nube para alimentar los algoritmos de predicción. Adaptado de "Anomaly detection for hydraulic power units—A case study" (p. 13), por P. Fic, A. Czornik & P. Rosikowski, 2023, Future internet, 15(6).

Se recomienda implementar arquitecturas de redes neuronales recurrentes (LSTM) en equipos rotativos clave (sopladores y bombas) para la detección temprana de patrones anómalos de vibración o consumo.


### 3. Argumento 2

#### Optimización adaptativa

Una vez asegurada la estabilidad del sistema y el mantenimiento predictivo de equipos, el siguiente desafío operativo es la respuesta a amenazas externas. Aquí la IA también juega un papel fundamental, aportando la optimización adaptativa, lo que permite no depender de un flujo de entrada constante. Sino que se adapta a la variedad del influente, optimizando recursos eficientemente y sin tener una librería extensa de datos dotándola de robustez operativa

En sistemas reales el caudal de entrada o influente para cualquier proceso dentro de una planta de tratamiento de aguas residuales no siempre será la misma, dándole complejidad a la tarea de adecuar los parámetros para lograr el tratamiento. En un estudio aplicado al proceso de fangos activados, el influente presentó una variación brusca en el caudal y contaminación (figura 5), provocando perturbaciones constantes a una PTAR. Haciendo imprescindible la tarea de que el sistema de control se logre adaptar a estas condiciones para mantener la calidad del efluente deseada (Sánchez et al., 2024).

**Figura N° 5:** Caudal en los reactores del proceso de fangos activados



**Fuente:** Adaptado de "Influencia de la temperatura y las acciones de control en las reacciones biológicas del proceso de fangos activados" (p. 3), por L. Sánchez, 2024, Jornadas de Automática, (45).

Los autores señalan que los picos repentinos de volumen de influente (figura 5) desestabilizan continuamente el tratamiento biológico (fangos activados). Por lo tanto, es una necesidad absoluta contar con un sistema de control que pueda modificar su propio funcionamiento sobre la marcha para asegurar que el agua tratada siga cumpliendo los estándares. Esta observación es imprescindible debido a que ilustra cómo la variabilidad del influente actúa como un evento desestabilizante para la biomasa de la planta, generando percances. Un sistema de control tradicional, calibrado para un escenario promedio, colapsa ante estas variaciones bruscas. La adaptabilidad algorítmica se convierte entonces no en una simple mejora de eficiencia, sino en un requisito operativo crítico para absorber estos impactos sin sacrificar la calidad del efluente final.

Frente a ello hay algunas alternativas que están emergiendo como AquaFlowNet que está marcando un avance significativo en la gestión inteligente de sistemas de aguas residuales al introducir el ML en las operaciones de control de flujo dinámico. El agente RL-DFC se adapta continuamente a las condiciones hidráulicas entrantes, lo que permite refinar sus decisiones con cada nuevo estado ambiental y generar respuestas cada vez más óptimas a lo largo del tiempo logrando así una reducción del 52% en el volumen total de desbordamiento, hasta un 90% de reducción en los eventos de desbordamiento y una mejora del 35-40% en la atenuación del flujo máximo (Alluhaidan et al., 2025). El estudio introduce el agente (RL-DFC) el cual utilizando el ML aprende dinámicamente de la base de datos brindada. Logrando así adaptarse a las fluctuaciones de influente de manera rápida y precisa, reduciendo casi en su totalidad la frecuencia de los desbordes y suavizar significativamente los picos del caudal, mejorando su respuesta con la experiencia acumulada. Lo revolucionario de este enfoque es el cambio de una optimización reactiva a una evolutiva. La capacidad de la mejora en la toma de decisiones implica que el sistema no solo resiste la variabilidad, sino que la utiliza para entrenarse y volverse más eficiente. Es recomendable lograr una implementación del RL en zonas urbanas vulnerables a lluvias torrenciales, para garantizar una amortiguación autónoma de las variaciones presentes por fenómenos naturales.

Las PTAR son infraestructuras con un consumo energético masivo, donde el gasto incesante en electricidad y reactivos químicos compromete la viabilidad financiera. Aunque la inversión inicial puede ser considerable, la implementación de herramientas inteligentes como un modelo de regresión basado en ML, puede generar ahorros sustanciales en los costos operativos durante la vida útil de la instalación. Entre los beneficios sustanciales, estas estrategias de control avanzado mejoran el rendimiento de las PTAR y reducen el consumo de recursos al optimizar el uso de energía (un 49% menos en comparación al uso tradicional) y productos químicos" (Cairone et al., 2024). La modernización de plantas con IA, pese a su alto coste inicial, demuestra ser rentable a largo plazo. Los modelos de ML optimizan el consumo de energía y químicos, reduciendo drásticamente los gastos operativos diarios. Con esto se deja en claro que la implementación de tecnologías modernas en las PTAR deja de verse como gasto innecesario y se convierte en una estrategia financiera a largo plazo. Tradicionalmente, las plantas operan con márgenes de seguridad amplios, lo que resulta en un gasto muy grande. Al delegar el control a herramientas inteligentes, se elimina este margen de error humano

y exceso de precaución, garantizando la sostenibilidad económica de la infraestructura a largo plazo sin sacrificar la calidad del tratamiento.

Adentrándonos en el proceso de tratamiento de aguas residuales la etapa de mayor consumo energético es la aireación biológica dada que es altamente no lineal. La aireación representa entre el 30% - 76% del consumo energético total. El modelo LSTM pronosticó eficazmente la dinámica del oxígeno disuelto (OD), lo que permitió al sistema ajustar la aireación de forma proactiva. La estrategia de control redujo el consumo de electricidad por unidad de influente (kWh/m<sup>3</sup>) y por unidad de DQO eliminada (kWh/ton-DQO). Estas mejoras condujeron a una reducción estimada de los gastos operativos (OPEX) anuales de \$180,000 (Xiong et al., 2025). Los investigadores comprobaron en una planta a escala real que las redes neuronales (LSTM) aprenden a predecir hacia dónde se moverán los niveles de oxígeno antes de que ocurra el cambio. Esta capacidad de inyectar el aire exacto en el momento preciso logró una estabilidad biológica superior y erradicó el desperdicio eléctrico, generando un ahorro comprobado de 180,000 dólares en un solo año. La optimización que genera el ML a la aireación se centra en predecir en lugar de corregir. En modelos tradicionales se inyecta aire de más por precaución o reacción tardía, desperdiciando gigavatios de energía. Al lograr una red neuronal suficientemente capaz de modelar la dinámica del oxígeno proactivamente se logró un ahorro masivo de dinero, manteniendo los equipos funcionando de manera ininterrumpida gracias a la eficiencia termodinámica lograda. Por lo tanto es altamente recomendable reemplazar progresivamente los bucles de control PID convencionales por arquitecturas basadas en ML predictivo (como LSTM-Fuzzy)

En un entorno real de funcionamiento, los sensores pueden fallar y las señales se ensucian. Un sistema de control robusto no es aquel que use todos los datos disponibles, sino aquel que sabe funcionar con el mínimo necesario, ignorando el ruido y tolerando la pérdida de variables no críticas. En un estudio, los valores atípicos se mantuvieron en el conjunto de datos, y se demostró que al centrarse en las variables más importantes, los modelos pueden ofrecer una alta precisión predictiva, a tal grado que solo 10 variables de entrada lograron una precisión tan alta como la del conjunto de datos completo (Nasir & Li, 2024). Los modelos de ML tienen la capacidad intrínseca de procesar datos inestables y aprender de los valores atípicos (ruido) sin desestabilizarse. Al aplicar técnicas de selección algorítmica, el ML filtra la información irrelevante, logrando predecir el comportamiento de la planta con exactitud utilizando apenas una pequeña fracción de todos los sensores disponibles. La vulnerabilidad más grande de los sistemas de automatización clásicos es que, si un sensor falla o envía lecturas erráticas (ruido), el sistema completo puede arrojar errores. Sin embargo, al comprobarse que los algoritmos de ML mantienen su máxima precisión utilizando un grupo reducido de variables esenciales (como 10 sensores en lugar de docenas), se demuestra que se crea un escudo de "tolerancia": el sistema sobrevive a la pérdida de datos periféricos porque el modelo matemático compensa el ruido entendiendo las dependencias no lineales de las variables más fuertes. Se aconseja emplear modelos de aprendizaje por conjuntos, como Random Forest (RF), durante la fase de auditoría de datos, ya que estos algoritmos manejan eficazmente la multicolinealidad, permitiendo identificar la

cantidad mínima de sensores necesarios para operar la planta de forma segura ante fallas de instrumentación.

La mayor barrera para implementar IA en plantas de tratamiento convencionales es la creencia de que se requieren sensores IoT de alta frecuencia costosos. En la realidad operativa, muchas instalaciones solo cuentan con registros históricos espaciados, como análisis de laboratorio semanales, lo que suele paralizar los proyectos de modernización algorítmica. Los hallazgos revelan que el rendimiento del modelo es altamente sensible a los cambios en las distribuciones de datos a lo largo del tiempo. Sin embargo, los modelos basados en árboles (Random Forest (RF), Extra Trees (ET) y XGBoost (XGB)) exhibieron una robustez superior al manejar datos de muestreo continuo de baja frecuencia (Khoshvaght et al., 2025). Se logró demostrar que, en escenarios de escasez severa de información (donde los datos no se toman cada minuto, sino cada semana), los algoritmos basados en árboles logran funcionar con éxito. A diferencia de las redes neuronales complejas que "mueren de hambre" sin grandes volúmenes de datos, estos modelos basados en árboles mantuvieron su capacidad predictiva utilizando únicamente muestreos semanales dispersos. Esto es de especial interés para romper el esquema del "Big Data" el cual no es necesario tener antes de modernizar una planta. Una instalación que cuenta con datos semanales de laboratorio puede lograr entrenar una IA funcional. En base a los avances tecnológicos de hoy en día, se debe optar por implementar modelos de Random Forest o XGBoost, ya que son matemáticamente los más aptos para generar valor operativo inmediato a partir de conjuntos de datos pequeños y de baja frecuencia.

#### **4. Argumento 3**

##### **La reducción de tiempo de espera de resultados**

Sin embargo, la eficiencia de esta robustez operativa y optimización de recursos depende exclusivamente de la velocidad de reacción del sistema. Por ello, otra de las bondades del ML es la reducción del tiempo de espera en la obtención de resultados, lo que permite la monitorización de parámetros de calidad en tiempo real, ejecutar acciones correctivas instantáneas y el análisis inmediato de resultados

La optimización de procesos mediante aprendizaje automatizado no solo resulta beneficioso en la eficiencia de una empresa, también fija los límites de seguridad de una planta. De acuerdo con la investigación de Hassan (2025), la integración de modelos predictivos permite que los operadores identifiquen con precisión el nivel óptimo de carga orgánica que el sistema puede soportar, lo cual se traduce en una mejora sustancial en la toma de decisiones y un mantenimiento estratégico más eficaz. En términos sencillos, el uso de ML actúa como un "copiloto inteligente" que avisa exactamente hasta qué punto se puede forzar la maquinaria sin que el agua salga sucia o el sistema se rompa. En tanto, el estudio demostró que el sistema funciona de manera ideal incluso cuando recibe un 30% más de suciedad de lo normal; sin embargo, al superar ese límite, la tecnología predice de inmediato que la calidad del agua fallará. Esta capacidad de anticipación es revolucionaria, pues permite que cualquier gestor de una planta, sin

importar las variaciones del entorno, pueda mantener el cumplimiento de las normas ambientales y evitar daños mecánicos costosos antes de que ocurran.

Bair et al. (2023), en su investigación sobre el desarrollo de sensores blandos basados en algoritmos de ML para predecir la calidad del agua en PTARs, demostraron la alta capacidad de predicción de parámetros críticos como la demanda química de oxígeno (COD) y los sólidos suspendidos totales (TSS) después de aplicar modelos de regresión. Al aplicar el algoritmo de Support Vector Regression (SVR), los autores obtuvieron un error cuadrático medio (RMSE) de 270 mg/L en la predicción de COD y coeficientes de determinación ( $R^2$ ) de hasta 0.96, esto evidencia una alta correlación entre los valores predichos y los datos reales. Esto nos indica que los modelos de aprendizaje automático pueden predecir parámetros críticos con suficiente precisión para apoyar o complementar la toma de decisiones operativas en tiempo real. Si bien es cierto, el ML no busca reemplazar completamente el análisis de datos en el laboratorio, actúa como herramienta para complementar y optimizar el monitoreo, reduciendo la frecuencia de análisis al obtener resultados en segundos o minutos y mejorar la eficiencia operativa.

Uno de los mayores beneficios del ML es la capacidad de respuesta rápida frente a cambios repentinos en el entorno. Barbu et al. (2025) en su estudio sobre el comportamiento de los contaminantes en efluentes de una planta de tratamiento de aguas en Suecia compararon tres modelos de ML basados en árboles (Random Forest, XGBoost y LightGBM) y tres arquitecturas de redes neuronales (LSTM, GRU y Transformer) (véase la tabla 1) con lo cual destacan que la red GRU demuestra un rendimiento robusto, adaptándose rápidamente a los aumentos repentinos y siguiendo de cerca las tendencias del efluente tanto en las fases de pico como de estabilización. Esto significa que hoy en día la IA captura información al instante y no pierde de vista a las variaciones repentinas en el flujo y la carga de un contaminante ante emergencias, superando a los métodos tradicionales que tardarían en detectar cambios bruscos en el proceso. Además, permiten que los operadores estén informados de que pasa con la calidad del agua sin la necesidad de esperar análisis manuales lentos.

**Tabla N° 1:** Desempeño y características de los métodos de aprendizaje supervisado (machine learning)

Modelo	Interpretabilidad	Rendimiento	Complejidad computacional	Capacidad en Tiempo Real	Requerimiento de datos
Random Forest <sup>a b</sup>	Alta Transparente mediante importancia de características	Alta Estándar base con R <sup>2</sup> excepcional	Moderada Diseño eficiente y masivamente paralelizable	Muy alta Inferencia instantánea altamente escalable.	Baja - Moderada Tolerante con datos ruidosos o incompletos
XGBoost <sup>a b</sup>	Moderada - Alta Puntuaciones difuminadas por naturaleza secuencial	Muy Alta Domina cinéticas no lineales complejas	Moderada - Alta Entrenamiento secuencial optimizado matemáticamente	Alta Reacción rápida en tiempos críticos	Moderada Requiere esquemas de selección superiores.
LightGBM <sup>a b</sup>	Moderada - Alta Identifica parámetros que impulsan reacciones.	Muy Alta Desempeño excepcional registrando MAE bajos.	Baja - Moderada Arquitectura liviana por crecimiento asimétrico.	Muy Alta Inferencia ultrarrápida para vectores masivos	Alta Eficiente procesando bases de datos masivas
GRU <sup>a c d</sup>	Baja Difícil extraer conclusiones, "Caja Negra"	Alta Aprende secuencias no lineales profundas.	Moderada Menor latencia utilizando dos compuertas	Moderada - Alta Ideal para ecosistemas Edge computing	Alta Requiere series temporales escrupulosamente tabuladas.
LSTM <sup>a b c d</sup>	Muy Baja Opacidad analítica estructural severa.	Muy Alta Domina en horizontes causales largos.	Alta - Muy Alta Entrenamiento extraordinariamente e costoso por compuertas.	Moderada Inferencia de secuencias largas consume CPU.	Muy Alta Requiere amplias muestras históricas perfectas.
Transformer <sup>a c</sup>	Moderada Parcialmente legible mediante mapas de atención	Muy Alta Puntuaciones récord procesando paralelamente	Muy Alta Demanda recursos computacionales drásticos.	Moderada - Alta Ralentizada por costos de entrenamiento	Muy Alta Necesita historiales puros y masivos de datos.

**Fuente:** En esta tabla se compara el desempeño, características y requerimiento de los modelos mencionados en Voipan, Voipan & Barbu (2025). a Zamfir, Carbureanu & Mihalache (2025, p. 3 - 35). b Dikmen et al. (2025, p. 1 - 10). c Ramya, Srinath & Tuppada (2025, p. 2 - 13). d Oliveira et al. (2024, p. 64 - 73)

El implementar modelos predictivos de aprendizaje automático permite que el personal de una planta obtenga información anticipada para tomar decisiones. Frente a esto, Guo et al. (2025) señalan que el personal de operaciones puede ajustar rápidamente los parámetros de operación gracias a la rápida predicción de resultados, estos incluyen la dosificación de la fuente de carbono y la tasa de aireación, en respuesta de los cambios repentinos de las condiciones de trabajo. Esto confirma que el ML no solo entrega datos, sino que elimina el tiempo de espera crítico de los métodos tradicionales; al conocer el estado futuro del agua, los ingenieros pueden ejecutar acciones correc-

tivas instantáneas en procesos clave como la aireación, garantizando que el sistema se adapte al cambio antes de que la calidad del efluente se vea comprometida.

Szczerska et al. (2025) destacan que la integración de sensores avanzados con modelos de aprendizaje automático no solo optimiza la vigilancia, sino que permite actuar de manera rápida antes de que un problema se propague. Según los autores, gracias al monitoreo continuo in situ de aguas residuales, se activa una vigilancia epidemiológica constante y de respuesta rápida al detectar señales inusuales. Esto permite a las autoridades de salud pública la inmediata toma de decisiones, producto de reemplazar análisis lentos propios de métodos tradicionales, obteniéndose un mecanismo de detección precoz frente a cambios en el proceso.

Diversos estudios han demostrado que la integración de arquitecturas basada en internet de las cosas (IoT) y ML permite la adquisición continua de datos y el monitoreo en tiempo real en sistemas de tratamiento de aguas residuales. Tal es el caso de Abekoon et al. (2025), quienes señalan que la implementación de tecnologías del internet facilita la adquisición y supervisión de datos en tiempo real mediante sensores que son procesados por modelos de aprendizaje automático que generan análisis inmediatos, apoyando la rapidez en la toma de decisiones. Este enfoque reduce la dependencia de análisis de laboratorios promoviendo una gestión adaptativa basada en datos. La integración de estas tecnologías permite optimizar el desempeño del sistema, incrementar la eficiencia y fortalecer la mejora continua del tratamiento. Implementar arquitecturas IoT y ML en las plantas de tratamiento, resulta relevante, ya que contribuye a la automatización, reducción de tiempos de espera y sostenibilidad operativa. Con lo cual, se recomienda desarrollar estrategias de digitalización progresiva que integren sensores inteligentes, plataformas de análisis y modelos predictivos, con el fin de mejorar la gestión de los procesos y garantizar un control más eficiente y confiable de los sistemas de tratamiento.

## **5. Argumento 4**

### **Transición hacia la automatización**

Finalmente, la capacidad de procesar datos al instante y ejecutar acciones correctivas en tiempo real no solo resuelve problemas diarios, sino que impulsa a las PTAR hacia su evolución tecnológica definitiva: la transición hacia la automatización bajo el marco de la industria 4.0.

Hasta la fecha, la optimización de los sistemas de tratamiento de aguas residuales dependía de la velocidad y precisión con la que se obtienen los datos analíticos. Sin embargo, la transición a la industria 4.0 ha permitido que los algoritmos de aprendizaje automático evolucionen la manera en que se analizan los datos a través de sus herramientas digitales avanzadas. Al respecto, Gulshin y Kuzina (2024) sostienen que existen modelos diseñados a partir de modelos de regresión, que implementados en sensores virtuales, son capaces de reemplazar parcialmente a sensores físicos, que además permiten reducir costos de planta. Esta innovación permite monitorear parámetros

complejos y eliminar el tiempo de espera de análisis químicos tradicionales. Si bien es cierto estos sistemas facilitan el monitoreo continuo de parámetros, lo cual significa un avance en la modernización permitiendo pasar de un enfoque reactivo a uno predictivo, su adopción requiere garantizar la calidad de datos proporcionados, la calibración continua de los modelos y la capacitación del personal para asegurar la confiabilidad de las predicciones y evitar decisiones operativas erróneas. En este sentido, el reto actual no radica únicamente en el desarrollo tecnológico, sino en la integración adecuada de estas herramientas dentro de la gestión de las plantas de tratamiento.

## 6. Conclusiones

En conclusión, la IA cambia el modo en el cual se puede operar una PTAR, sustituyendo la gestión reactiva (tradicional) por una preventiva (futuro). La evidencia demuestra que el uso de algoritmos basados en ML mitiga 3 principales problemas del tratamiento: Reduce la incertidumbre en fenómenos biológicos no lineales como el bulking con absoluta precisión, garantiza el cumplimiento normativo asegurando la calidad del efluente mediante la dosificación correcta de químicos y asegura la disponibilidad de los equipos a través del mantenimiento predictivo. Así, el ML despliega un fuerte uso en la detección temprana de anomalías y fallas.

Asimismo, la optimización adaptativa dotada por el ML transforma a las PTAR en sistemas dinámicos capaces de reaccionar ante fluctuaciones en el entorno y adaptarse a ellas. Gracias a la predicción dotada por la librería de datos el algoritmo permite amortiguar e inyectar oxígeno precisamente, ahorrando en gastos innecesarios. Dependiendo del modelo de aprendizaje autónomo que se elija como alguno basado en árboles (Random Forest, XGBoost) el algoritmo será dotado de robustez al poder trabajar con una librería de pocos datos.

En definitiva, existe una drástica reducción de tiempos de espera gracias a los mecanismos de aprendizaje autónomo de la IA. Al actuar como un asistente, se traduce instantáneamente el flujo de datos en señales, en advertencias para una toma de decisión activa asegurando así la rápida acción y el menor perjuicio a la PTAR y trabajadores.

Finalmente, se evidencia que la automatización hacia una industria 4.0 en el sector de saneamiento es una realidad pronta, por su factibilidad técnica y económica. La integración de soft sensors, permite la inferencia de estados fisicoquímicos del agua, sustituyendo la instrumentación tradicional. Esta innovación asegura una simplificación masiva en la recolección de datos, asegurando una lectura ininterrumpida que alimenta a sistemas de visualización y toma de decisiones como SCADA.

## 7. Literatura citada

- ABEKOON, A., BOGAHAWATHTHA, M., GANGANI, D., JANAKA A., MEDDAGE, D. (2025). A REVIEW OF MACHINE LEARNING AND INTERNET-OF-THINGS ON THE WATER QUALITY ASSESSMENT: METHODS, APPLICATIONS AND FUTURE TRENDS. *RESULTS IN ENGINEERING*, 26, 105182. [HTTPS://DOI.ORG/10.1016/J.RINENG.2025.105182](https://doi.org/10.1016/j.rineng.2025.105182)
- ALALOUL, W., ALAZAIZA, M., ALMUHAYA, B., AL-ZGHOUL, T., BAARIMAH, A., BAZEL, M., KHAN, A., MUSTHAHA, A. (2024). ARTIFICIAL INTELLIGENCE IN WASTEWATER TREATMENT: RESEARCH TRENDS AND FUTURE PERSPECTIVES THROUGH BIBLIOMETRIC ANALYSIS. *CASE STUDIES IN CHEMICAL AND ENVIRONMENTAL ENGINEERING*, 10, 100926. [HTTPS://DOI.ORG/10.1016/J.CSCEE.2024.100926](https://doi.org/10.1016/j.cscee.2024.100926)
- ALLUHAIKAN, A., PRABU, P., AZIZ, R. & BASHEER, S. (2025). ADAPTIVE WASTEWATER FLOW CONTROL USING AQUAFLOWNET WITH REINFORCEMENT LEARNING FOR URBAN DRAINAGE OPTIMIZATION. *APPLIED WATER SCIENCE*, 15, 19182. [HTTPS://LINK.SPRINGER.COM/ARTICLE/10.1007/S13201-025-02719-4#:~:TEXT=ADAPTIVE%20OPTIMIZATION%20OF%20VALVES%20AND,SCENARIOS%20OR%20UNEXPECTED%20INFLOW%20SPIKES](https://link.springer.com/article/10.1007/s13201-025-02719-4#:~:text=ADAPTIVE%20OPTIMIZATION%20OF%20VALVES%20AND,scenarios%20or%20unexpected%20inflow%20spikes)
- BAIR, R., CASTRO, J., LU, Q., SHYU, H., & YEH, D. (2023). DEVELOPMENT OF A SOFT SENSOR USING MACHINE LEARNING ALGORITHMS TO PREDICT WATER QUALITY IN AN ON-SITE WASTEWATER TREATMENT SYSTEM. *ACS ENVIRONMENTAL AU*, 3 (5), 308-318. [HTTPS://PUBS.ACS.ORG/DOI/10.1021/ACSENVIRONAU.2C00072](https://pubs.acs.org/doi/10.1021/acsenvironau.2c00072)
- BARBU, M., VOIPAN, D., VOIPAN, A. E.. (2025). EVALUATING MACHINE LEARNING-BASED SOFT SENSORS FOR EFFLUENT QUALITY PREDICTION IN WASTEWATER TREATMENT UNDER VARIABLE WEATHER CONDITIONS. *SENSORS*, 25 (6), 1692. [HTTPS://DOI.ORG/10.3390/S25061692](https://doi.org/10.3390/s25061692)
- BERTOLINI, M., MEZZOGORI, D., NERONI, M., ZAMMORI, F. (2021). MACHINE LEARNING FOR INDUSTRIAL APPLICATIONS: A COMPREHENSIVE LITERATURE REVIEW. *EXPERT SYSTEMS WITH APPLICATIONS*, 175, 114820. [HTTPS://DOI.ORG/10.1016/J.ESWA.2021.114820](https://doi.org/10.1016/j.eswa.2021.114820)
- CAIRONE, S., HASAN, S. CHOO, K., LEKKAS, D., FORTUNANOT, L., ZORPAS, A., KORSHIN, G., ZARRA, T., BELGIORNO, V. & NADDEO, V. (2024). REVOLUTIONIZING WASTEWATER TREATMENT TOWARD CIRCULAR ECONOMY AND CARBON NEUTRALITY GOALS: PIONEERING SUSTAINABLE AND EFFICIENT SOLUTIONS FOR AUTOMATION AND ADVANCED PROCESS CONTROL WITH SMART AND CUTTING-EDGE TECHNOLOGIES. *JOURNAL OF WATER PROCESS ENGINEERING*, 63, 105486. [HTTPS://WWW.SCIENCEDIRECT.COM/SCIENCE/ARTICLE/PII/S2214714424007189](https://www.sciencedirect.com/science/article/pii/S2214714424007189)
- DIKMEN, F., DEMIR, A., ÖZKAYA, B., OWAIS, M., RASHEED, J., ASUROGLU, T. & ALSUBAI, S. (2025). AI-DRIVEN WASTEWATER MANAGEMENT THROUGH COMPARATIVE ANALYSIS OF FEATURE SELECTION TECHNIQUES AND PREDICTIVE MODELS. *SCIENTIFIC REPORTS*, 15(25347). [HTTPS://WWW.NATURE.COM/ARTICLES/S41598-025-07124-0](https://www.nature.com/articles/s41598-025-07124-0)
- FIC, P., CZORNIK, A. & ROSIKOWSKI, P. (2023). ANOMALY DETECTION FOR HYDRAULIC POWER UNITS—A CASE STUDY. *FUTURE INTERNET*, 15(6), 206. [HTTPS://WWW.MDPI.COM/1999-5903/15/6/206](https://www.mdpi.com/1999-5903/15/6/206)

- GULSHIN, I. & KUZINA, O. (2024). MACHINE LEARNING METHODS FOR THE PREDICTION OF WASTEWATER TREATMENT EFFICIENCY AND ANOMALY CLASSIFICATION WITH LACK OF HISTORICAL DATA. *APPLIED SCIENCES*, 14(22). [HTTPS://WWW.MDPI.COM/2076-3417/14/22/10689](https://www.mdpi.com/2076-3417/14/22/10689)
- GUO, X., JIANG, H., LI, H., LI, X., LIU, C., SUN, H., & MIAO, S. (2025). APPLYING MACHINE LEARNING APPROACH TO DESIGN OPERATIONAL CONTROL STRATEGIES FOR A WASTEWATER TREATMENT PLANT IN TYPICAL SCENARIOS. *WATER*, 17 (3), 310. [HTTPS://DOI.ORG/10.3390/W17030310](https://doi.org/10.3390/w17030310).
- HASSAN, H. (2025) MACHINE LEARNING APPLICATION IN MUNICIPAL WASTEWATER TREATMENT TO ENHANCE THE PERFORMANCE OF A SEQUENCING BATCH REACTOR WASTEWATER TREATMENT PLANT. *ENVIRONMENTAL SCIENCE: ADVANCES*, 1, 1-11. [HTTPS://DOI.ORG/10.1039/D4VA00285G](https://doi.org/10.1039/D4VA00285G)
- KHOSHVAGHT, H., RAMYAD, R., RAZMJOU, A. & KHIADANI, M. (2025). FACTORS INFLUENCING THE EFFECTIVENESS OF MACHINE LEARNING ALGORITHMS IN PREDICTING RAW WASTEWATER CHARACTERISTICS: AN ANALYSIS BASED ON WEEKLY FIELD DATA. *JOURNAL OF WATER PROCESS ENGINEERING*, 78, 108702. [HTTPS://WWW.SCIENCEDIRECT.COM/SCIENCE/ARTICLE/PII/S2214714425017751](https://www.sciencedirect.com/science/article/pii/S2214714425017751)
- LLAMUCA, S. Y BAYAS, M. (2025). GENERACIÓN DE UN MODELO ESTADÍSTICO PARA LA AUTOMATIZACIÓN DEL CONTROL DE LOS PARÁMETROS DE CALIDAD DEL AGUA, DE LA PLANTA DE TRATAMIENTO DE AGUA POTABLE EL CARRIZAL, PERTENECIENTE A LA PARROQUIA SAN MIGUEL, DEL CANTÓN SALCEDO, PROVINCIA DE COTOPAX. *IMPACT RESEARCH JOURNAL*, 3(2), 261 - 285. [HTTPS://WWW.EDITORIALSPHAERA.COM/INDEX.PHP/IMP/ARTICLE/VIEW/201/491](https://www.editorialspheera.com/index.php/imp/article/view/201/491)
- MARIN, J. (2024). PROTOTIPO DE MODELO DE INTELIGENCIA ARTIFICIAL PARA MEJORAR LA DOSIFICACIÓN QUÍMICA EN EL PROCESO DE TRATAMIENTO DE AGUAS RESIDUALES DE LA INDUSTRIA TEXTIL. [TESIS DE GRADO, UNIVERSIDAD EAN] [HTTPS://REPOSITORY.UNIVERSIDADEAN.EDU.CO/SERVER/API/CORE/BITSTREAMS/241642DF-C2F4-4B69-BFBE-061F42F71472/CONTENT](https://repository.universidadean.edu.co/server/api/core/bitstreams/241642df-c2f4-4b69-bfbe-061f42f71472/content)
- NASIR, F. & LI, J. (2024). UNDERSTANDING MACHINE LEARNING PREDICTIONS OF WASTEWATER TREATMENT PLANT SLUDGE WITH EXPLAINABLE ARTIFICIAL INTELLIGENCE. *WATER ENVIRONMENT RESEARCH*, 96(10). DOI: 10.1002/wer.11136
- OLIVEIRA, P., SUPINO, F., DUARTE, S. & DURAES, D. (2024). ASSESSMENT OF LSTM AND GRU MODELS TO PREDICT THE ELECTRICITY PRODUCTION FROM BIOGAS IN A WASTEWATER TREATMENT PLANT. *GOOD PRACTICES AND NEW PERSPECTIVES IN INFORMATION SYSTEMS AND TECHNOLOGIES*. (PP. 64-73). [HTTPS://REVISTAS.UDC.ES/INDEX.PHP/JA\\_CEA/ARTICLE/VIEW/10960](https://revistas.udc.es/index.php/JA_CEA/article/view/10960)
- RAMYA, S., SRINATH, S. & TUPPAD, P. (2025). DATA DRIVEN MULTI-STAGE TRANSFORMER BASED FRAMEWORK FOR INTELLIGENT WATER QUALITY MONITORING. *SCIENTIFIC REPORTS*, 15(41680). [HTTPS://WWW.NATURE.COM/ARTICLES/S41598-025-25527-X](https://www.nature.com/articles/s41598-025-25527-x)
- SANABRIA, G., Y REGIL-VARGAS, L. (2024). INTELIGENCIA ARTIFICIAL PARA LA RECOMENDACIÓN DE RECURSOS EN EDUCACIÓN EN LÍNEA. *APERTURA (GUADALAJARA, JAL.)*, 16(2), 6-21. [HTTPS://DOI.ORG/10.32870/AP.V16N2.2542](https://doi.org/10.32870/ap.v16n2.2542)

- SÁNCHEZ, L., REVOLLAR, S., FRANCISCO, M., VEGA, P., MENESES, M. Y VILANOVA, R. (2024) INFLUENCIA DE LA TEMPERATURA Y LAS ACCIONES DE CONTROL EN LAS REACCIONES BIOLÓGICAS DEL PROCESO DE FANGOS ACTIVADOS. *JORNADAS DE AUTOMÁTICA*, (45). DOI: 10.17979/JACEA.2024.45.10960
- SZCZERSKA, M. ET AL. (2025). REMOTE REAL-TIME WASTEWATER SURVEILLANCE BY THE OPTICAL SENSOR SUPPORTED BY MACHINE LEARNING. *SENSORS AND ACTUATORS REPORTS*, 10, 100346. [HTTPS://DOI.ORG/10.1016/J.SNR.2025.100346](https://doi.org/10.1016/j.snr.2025.100346).
- TAPIA, S., AGUILERA, G., ROJAS, L. Y GARCÍA, J. (2024). MANTENIMIENTO PREDICTIVO BASADO EN MACHINE LEARNING: UNA REVISIÓN SISTEMÁTICA DE LA LITERATURA Y PERSPECTIVAS EN LA INDUSTRIA 4.0. *AVANCES EN CIENCIAS E INGENIERÍA*, 15 (4), 63 - 93 [HTTPS://ACIJOURNAL.CL/INDEX.PHP/OJS/ARTICLE/DOWNLOAD/3/51](https://acijournal.cl/index.php/ojs/article/download/3/51)
- XIONG, Z., CHENG, L., IBRAHIM, A., JIAN, D., ZHANG, X., IGOU, T., TONG, S. & CHEN, Y. (2025). MACHINE LEARNING-ASSISTED EXPERT CONTROL IN WASTEWATER AERATION TREATMENT PROCESS APPLICATION. *ACS ES&T ENGINEERING*, 5(11), 3140-3152. [HTTPS://PUBS.ACS.ORG/DOI/PDF/10.1021/ACSESTENGG.5C00493?REF=ARTICLE\\_OPENPDF](https://pubs.acs.org/doi/pdf/10.1021/acsestengg.5c00493?ref=article_openpdf)
- ZAMFIR, F., CARBUREANU, M. & MIHALACHE, F. (2025). APPLICATION OF MACHINE LEARNING MODELS IN OPTIMIZING WASTEWATER TREATMENT PROCESSES: A REVIEW. *APPLIED SCIENCES*, 15(15). [HTTPS://WWW.MDPI.COM/2076-3417/15/15/8360](https://www.mdpi.com/2076-3417/15/15/8360)
- SASIENI, MAURICE. (1994). INTRODUCCIÓN A LA INVESTIGACIÓN DE OPERACIONES. MEXICO. LIMUSA.
- SETO, WILLIAM. (1964). THEORY AND PROBLEMS OF MECHANICAL VIBRATIONS. NEW YORK. SCHAUM PUBLISHING CO.
- STÖHR, W. (1985). SELECTIVE SELFRELIANCE AND ENDOGENOUS REGIONAL DEVELOPMENT, UNGLEICHE ENTWICKLUNG UND REGIONALPOLITIK IN SÜDEUROPA. ED. NOHLEN & SCHULTZE, STUDIENVERLAG DR. N. BROCKMEYER. BOCHUM.
- WORLD COMMISSION ON ENVIRONMENT AND DEVELOPMENT. (1987). OUR COMMON FUTURE. UNITED NATIONS.

# ÍNDICE DE IMÁGENES



De izquierda a derecha

1. [https://www.vectorizados.com/vector/12952\\_pez-mecanico/#google\\_vignette](https://www.vectorizados.com/vector/12952_pez-mecanico/#google_vignette)
2. [https://www.rawpixel.com/image/2828388/free-illustration-png-shopping-social-media-shop?utm\\_medium=organic&utm\\_source=Pinterest](https://www.rawpixel.com/image/2828388/free-illustration-png-shopping-social-media-shop?utm_medium=organic&utm_source=Pinterest)
3. [https://cgworld.jp/interview/images/201612\\_Aiming/201612\\_Aiming\\_a3.jpg](https://cgworld.jp/interview/images/201612_Aiming/201612_Aiming_a3.jpg)
4. [https://stock.adobe.com/pe/stock-photo/id/1057997516?utm\\_source=Pinterest&utm\\_medium=organic&epik=djoyJnUgZ3lZbmNiTDhxUDl-jaiZRaXEyZE1LamFrMDh4TXVrTlcmcDowJm49VkhadGJkdExMaVM-2cXV5SkZkUopyQSZoPUFBQUFBR255Tks4https://es.pinterest.com/priyankaminnu/](https://stock.adobe.com/pe/stock-photo/id/1057997516?utm_source=Pinterest&utm_medium=organic&epik=djoyJnUgZ3lZbmNiTDhxUDl-jaiZRaXEyZE1LamFrMDh4TXVrTlcmcDowJm49VkhadGJkdExMaVM-2cXV5SkZkUopyQSZoPUFBQUFBR255Tks4https://es.pinterest.com/priyankaminnu/)
5. [https://es.pngtree.com/freepng/cleaning-service-eco-wiper-business-logo-design-template-vector\\_5101197.html?utm\\_source=Pinterest&utm\\_medium=organic](https://es.pngtree.com/freepng/cleaning-service-eco-wiper-business-logo-design-template-vector_5101197.html?utm_source=Pinterest&utm_medium=organic)

# Ciencias e Ingeniería



<https://ctscafe.pe/index.php/cienciaingenieria>  
Volumen II- N° 4 Abril 2026

Contáctenos en nuestro correo electrónico  
**[cienciaseingenierias@ctscafe.pe](mailto:cienciaseingenierias@ctscafe.pe)**

Página Web:  
**<https://ctscafe.pe/index.php/cienciaingenieria>**