SenseCaps: An Intelligent Adaptive Filtration System for Copper Mining Wastewater Treatment Using Machine Learning

Ronald Barahona[1], Pablo Castro[2], Sofía Cornejo[3], Antonio Morán[4], Xiomara Piriz[5]
[1,3]Universidad de La Frontera, Chile, r.barahona02@ufromail.cl, s.cornejo01@ufromail.cl
[2]Universidad Tecnológica del Perú, Perú, pablocesar.castrotimana@gmail.com
[4]Escuela Superior Politécnica de Chimborazo, Ecuador, antonio.moran@espoch.edu.ec
[5]Universidad Tecnológica Nacional Facultad Regional Delta, Argentina, xpiriz@frd.utn.edu.ar

Abstract*— Mining activity is a major source of water contamination due to the presence of heavy metals and physicochemical fluctuations that hinder water reuse in industrial processes. Conventional treatment systems typically operate under fixed configurations, limiting their ability to adapt to variations in effluent composition. As a result, filter media are used inefficiently, leading to increased maintenance requirements and higher operating costs. This paper presents SenseCaps, an intelligent and adaptive treatment system designed for water affected by copper mining activities. The proposed system integrates a network of sensors for real-time water quality characterization, a modular filtration train with hydraulically independent treatment units, and machine learning algorithms that determine the optimal treatment strategy according to the physicochemical characteristics of the influent. In addition, the system continuously monitors operational variables to optimize filter cartridge replacement through predictive maintenance. Consequently, SenseCaps enhances operational flexibility, improves the efficiency of filtration resources, and contributes to more sustainable and efficient water management in the mining industry.

Keywords*— Mining effluent treatment, Modular adaptive filtration, Edge computing, PLC, Machine learning.

SenseCaps: Un Sistema Inteligente y Adaptativo de Filtración para el Tratamiento de Aguas Residuales de Minería de Cobre mediante Aprendizaje Automático.

Ronald Barahona[1], Pablo Castro[2], Sofía Cornejo[3], Antonio Morán[4], Xiomara Piriz[5]
[1,3]Universidad de La Frontera, Chile, r.barahona02@ufromail.cl, s.cornejo01@ufromail.cl
[2]Universidad Tecnológica del Perú, Perú, pablocesar.castrotimana@gmail.com
[4]Escuela Superior Politécnica de Chimborazo, Ecuador, antonio.moran@espoch.edu.ec
[5]Universidad Tecnológica Nacional Facultad Regional Delta, Argentina, xpiriz@frd.utn.edu.ar

Resumen– ***La actividad minera constituye una de las principales fuentes de contaminación de los recursos hídricos debido a la presencia de metales pesados y variaciones fisicoquímicas que dificultan la reutilización del agua en los procesos productivos. Los sistemas convencionales de tratamiento suelen operar mediante configuraciones fijas, las cuales presentan limitaciones para adaptarse a las variaciones en la composición del efluente, lo que provoca un uso ineficiente de los medios filtrantes y mayores costos de operación al incrementar las tareas de mantenimiento.***

Se presenta SenseCaps, un sistema inteligente de tratamiento adaptativo para aguas provenientes de la minería del cobre. La propuesta integra una red de sensores para la caracterización en tiempo real de la calidad del agua, un tren de filtración con módulos hidráulicamente independientes y algoritmos de aprendizaje automático capaces de seleccionar la estrategia de tratamiento más adecuada de acuerdo con las condiciones del efluente. Asimismo, incorpora monitoreo continuo de variables operacionales para optimizar el reemplazo de cartuchos filtrantes mediante estrategias de mantenimiento predictivo. De esta forma, se logra incrementar la flexibilidad operacional del sistema, optimizar el uso de los recursos de filtración y contribuir a una gestión más eficiente y sostenible del recurso hídrico en la industria minera.

Palabras clave— ***Tratamiento de efluentes mineros, Filtración adaptativa modular, Edge Computing, PLC, Aprendizaje automático.***

I. Introducción

La gestión eficiente del agua representa uno de los principales desafíos para la industria minera. En 2024, la minería del cobre en Chile registró que un 71% del agua utilizada fue recirculada, mientras que el agua continental representó el 19,1% [1]. Estas cifras evidencian la importancia de optimizar la gestión hídrica, mediante tecnologías como SenseCaps que están orientadas a mejorar la recuperación y reutilización del agua marginal, manteniendo una calidad de tratamiento consistente y reduciendo tanto los costos como los riesgos operacionales. En particular, la minería del cobre genera efluentes con una composición variable, caracterizados por la presencia de metales pesados y alteraciones en parámetros como el pH. Estas condiciones hacen necesaria la implementación de sistemas de tratamiento capaces de responder de forma dinámica a las variaciones del proceso.

Actualmente, la mayoría de las plantas de tratamiento emplean trenes de filtración de configuración fija, diseñados para operar bajo condiciones estáticas. Estos sistemas carecen de flexibilidad ante fluctuaciones en la calidad del agua, ya que mantienen activas todas las etapas de filtrado independientemente del nivel real de contaminación. Esto provoca un desgaste acelerado de los medios filtrantes y un incremento sustancial en los costos de operación y mantenimiento.

En los últimos años, la integración de IoT, sensores industriales, Edge Computing e IA ha impulsado sistemas de tratamiento más inteligentes con monitoreo en tiempo real. Sin embargo, la arquitectura mecánica de los sistemas de filtración continúa siendo poco flexible frente a las dinámicas variaciones del efluente.En este contexto, se propone SenseCaps, un sistema inteligente de tratamiento adaptativo para efluentes mineros.

II. Metodología

A continuación se presenta un diagrama del flujo del agua e información del Sistema SenseCaps para lograr un mejor entendimiento de la integración de cada sección.

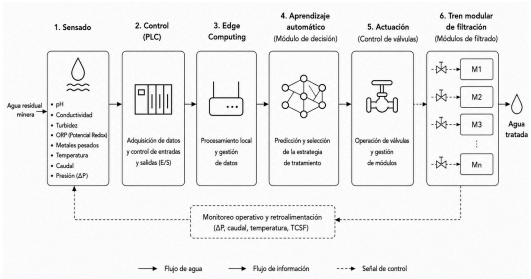


Fig. 1 Arquitectura general y flujo de información SenseCaps

A. *Sistema de adquisición de datos y control automatizado*

La primera etapa del sistema SenseCaps corresponde a la caracterización del agua contaminada mediante una red de sensores especializados, cuyo objetivo es determinar las condiciones fisicoquímicas del flujo y establecer el tratamiento más adecuado según los contaminantes presentes.

En particular, los procesos asociados a la minería del cobre generan aguas con variaciones en parámetros críticos como pH, turbidez, potencial óxido-reducción (ORP), conductividad eléctrica, concentración de sulfatos y presencia de metales pesados, entre los que destacan cobre (Cu), arsénico (As) y aluminio (Al). Estas alteraciones pueden estar asociadas a fenómenos como la generación de drenaje ácido de mina y la movilización de elementos metálicos desde los residuos mineros hacia los cuerpos de agua, lo que afecta su calidad y limita su uso posterior [2].

Para realizar una caracterización precisa del agua que ingresa al sistema, se seleccionan tecnologías de sensado específicas según la variable a monitorear. En la Tabla I se presentan los sensores seleccionados en base a cuatro criterios: (1) Compatibilidad con ambientes corrosivos y de alta conductividad iónica propios de efluentes cupríferos, (2) Resolución para detectar variaciones tempranas que disparen la reconfiguración del tren de filtración, (3) Tiempo de respuesta compatible con el ciclo de control en tiempo real del sistema, y (4) Disponibilidad de salida estandarizada para integración directa con el PLC.

TABLA I
TECNOLOGÍAS DE SENSORES UTILIZADAS EN EL SISTEMA SENSECAPS

Parámetro	Sensor	Rango de medición	Precisión	Tiempo de respuesta	Salida
pH	Potenciómetro	0–14 pH	±0,02–0,1 pH / 0,01 pH	<10 s (T90)	4–20 mA / RS-485
Conduct. elect.	Conductimétrico	0–200 mS/cm	±0,5 % lectura	—	4–20 mA / RS-485
Turbidez	Óptico nefelométrico	0–1000 NTU	±2–5 % FS / 0,1 NTU	≤30 s	4–20 mA / RS-485
ORP	Electroquímico	-1000 a +1000 mV	±1–2 mV / 1 mV	<5 s	4–20 mA / RS-485
Metales pesados	Amperométrico	ppb–ppm	LOD hasta orden 10^{-10} M	1–4 min/ciclo	RS-485 / comunicación digital

La caracterización multidimensional del agua en tiempo real genera la base de información que SenseCaps utiliza para seleccionar de forma adaptativa el módulo de tratamiento más apropiado. Para lograrlo, el sistema incorpora una arquitectura de control que combina un PLC y una unidad de Edge Computing.

El PLC gestiona las señales analógicas y digitales de los sensores, aportando operación continua y respuesta determinística ante cambios del proceso [3]. Dada la complejidad de seleccionar dinámicamente el tratamiento requerido, SenseCaps suma la capa de Edge Computing, que procesa localmente los datos de los sensores y permite generar respuestas rápidas ante variaciones en los parámetros monitoreados [4], determinando así el módulo de filtración más adecuado.

Esta decisión es enviada de vuelta al PLC, que dirige el flujo de agua mediante el accionamiento coordinado de válvulas motorizadas, transformando el monitoreo en una respuesta física capaz de adaptarse al efluente en tiempo real.

TABLA II
ESPECIFICACIONES DE LOS CONTROLADORES DEL SISTEMA SENSECAPS

Unidad	**Especificaciones**	**Comunicación/ Alimentación**
PLC (Siemens S7-1200, CPU 1214C)	14 entradas digitales, 2 entradas analógicas, 10 salidas digitales	Ethernet/RS-485 · 24 V DC
Edge Computing (gateway industrial tipo Raspberry Pi CM4/Jetson)	CPU ARM multinúcleo, 4–8 GB RAM	Wi-Fi/LoRaWAN/4G/Ethernet · 12–24 V DC

A diferencia de los trenes convencionales de secuencia fija, la arquitectura propuesta emplea módulos filtrantes independientes que se incorporan o aíslan selectivamente según las características del agua detectadas, reduciendo el uso innecesario de medios filtrantes y distribuyendo la carga de trabajo entre módulos. Esta optimización es relevante porque el reemplazo de cartuchos y el mantenimiento representan una parte importante del costo operacional en sistemas industriales de tratamiento de agua [5].

En la minería del cobre, los componentes asociados a servicios de terceros (mantenimiento y operación) y materiales (consumibles e insumos) representan el 31% y 17% del costo de explotación total, respectivamente [1]. En este contexto, la arquitectura modular adaptativa de SenseCaps permite mitigar dicho impacto al reducir el desgaste prematuro de los medios filtrantes, distribuyendo de manera uniforme la carga de trabajo y extendiendo los intervalos de recambio.

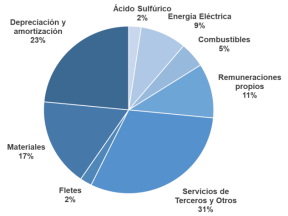


Fig. 2 Costos de explotación de la minería del cobre

Cada módulo integra un housing a presión que aloja cartuchos filtrantes reemplazables, fabricados con materiales resistentes a la corrosión y aptos para condiciones industriales [7]. Se emplean cartuchos de microfibra plisada de filtración absoluta, eficientes en la retención de sólidos finos y en la protección de las etapas posteriores [8]-[9].

El estado de cada cartucho se monitorea mediante sensores de presión antes y después del mismo, calculando la presión diferencial (ΔP) como indicador de colmatación [9]. A partir de ΔP, caudal y temperatura, el PLC estima el flujo específico corregido por temperatura (permeabilidad del cartucho) [8]. Al superar el umbral establecido, el sistema aísla automáticamente el módulo y programa el reemplazo del cartucho, sin interrumpir el proceso ni afectar la calidad del agua tratada.

B. Diseño de los Módulos Filtrantes Adaptativos

Con base en la caracterización obtenida durante la etapa de monitoreo, el sistema SenseCaps selecciona dinámicamente los módulos filtrantes que presentan mayor afinidad con los contaminantes detectados. La arquitectura propuesta activa únicamente los módulos requeridos para cada condición de operación, esto optimiza el aprovechamiento de los medios adsorbentes y reduce las pérdidas de carga y los costos de mantenimiento.

La selección de los materiales filtrantes se realizó mediante una revisión de la literatura relacionada con el tratamiento de efluentes mineros y drenajes ácidos de mina, se priorizó según capacidad de adsorción, estabilidad química, disponibilidad comercial y aplicación a escala industrial. Cada módulo fue diseñado para atacar un grupo específico de contaminantes, lo cual permite la configuración automática de la secuencia de tratamiento más adecuada según las condiciones del agua.

La Tabla II resume la composición propuesta para cada módulo filtrante y su función principal dentro del sistema.

TABLA III
COMPOSICIÓN Y FUNCIÓN DE LOS MÓDULOS FILTRANTES

Módulo	Medio filtrante principal	Función
1	Arena sílica, antracita y granate	Remoción de sólidos suspendidos y reducción de turbidez
2	Calcita, dolomita y MgO	Neutralización del drenaje ácido y ajuste de pH
3	Resina quelante, clinoptilolita y biochar modificado con Fe	Adsorción selectiva de metales pesados
4	GFH, Bayoxide® E33 y alúmina activada	Remoción de arsénico y otros metaloides
5	Carbón activado granular	Adsorción de reactivos orgánicos residuales de flotación
6	Organoclay, material oleofílico y carbón activado	Remoción de hidrocarburos y grasas

Módulo 1. Remoción de sedimentos y sólidos suspendidos

El primer módulo constituye una etapa de pretratamiento destinada a reducir la carga de sólidos suspendidos y disminuir la turbidez del agua antes de ingresar a las etapas de adsorción química. Para ello se propone un filtro multimedia compuesto por arena sílica, antracita y granate, configuración ampliamente utilizada en plantas de tratamiento debido a la diferencia de densidades y tamaños de partícula entre los medios filtrantes. Esta disposición favorece la filtración en profundidad, pues incrementa la retención de partículas de diferentes tamaños y reduce el riesgo de colmatación de los módulos posteriores. La eliminación temprana de sólidos suspendidos mejora además la eficiencia de los adsorbentes utilizados en las etapas posteriores al disminuir el ensuciamiento superficial [11].

Módulo 2. Neutralización de acidez

La segunda etapa tiene como finalidad corregir las condiciones de acidez características del drenaje ácido de minas mediante un lecho reactivo conformado por calcita, dolomita y óxido de magnesio. Estos materiales liberan progresivamente especies alcalinas capaces de incrementar el pH del agua y favorecer la precipitación de diversos metales disueltos. La neutralización previa resulta especialmente importante debido a que numerosos adsorbentes presentan un desempeño significativamente mayor cuando operan en condiciones cercanas a la neutralidad. El empleo conjunto de carbonatos y óxidos alcalinos permite mantener una capacidad amortiguadora sostenida durante la operación, constituyendo una estrategia ampliamente utilizada en sistemas pasivos de tratamiento de drenajes ácidos [12]-[13].

Módulo 3. Remoción selectiva de metales pesados

Para la eliminación de metales pesados disueltos se propone un medio compuesto por resinas quelantes, clinoptilolita natural modificada y biochar enriquecido con óxidos de hierro. Las resinas quelantes presentan alta selectividad hacia cationes metálicos mediante mecanismos de complejización química, mientras que la clinoptilolita contribuye mediante intercambio iónico y adsorción superficial. Por otra parte, el biochar modificado con hierro incrementa considerablemente el número de sitios activos disponibles para la retención de metales, mejorando la capacidad adsorbente respecto al biochar convencional. La combinación de estos materiales permite ampliar el rango de metales susceptibles de ser removidos y aumentar la eficiencia del tratamiento frente a concentraciones variables de contaminantes [14]-[15].

Módulo 4. Remoción de arsénico y metaloides

Para la remoción específica de arsénico y otros metaloides presentes frecuentemente en efluentes de la minería del cobre se propone la utilización de hidróxido férrico granular (GFH), Bayoxide® E33 y alúmina activada, materiales ampliamente empleados por su elevada afinidad química hacia especies arsenicales. La adsorción ocurre principalmente mediante la formación de complejos superficiales sobre grupos hidroxilo presentes en los óxidos de hierro y aluminio, mecanismo que permite alcanzar altas eficiencias incluso a bajas concentraciones del contaminante. La incorporación de este módulo resulta particularmente relevante para zonas andinas, donde el arsénico puede encontrarse asociado tanto a procesos geológicos naturales como a actividades extractivas [16]-[17].

Módulo 5. Remoción de reactivos orgánicos de flotación

Los procesos de concentración por flotación generan residuos de reactivos orgánicos, tales como colectores, espumantes y modificadores, que pueden permanecer disueltos en el agua residual. Para la remoción de estos compuestos se propone un lecho de carbón activado granular (GAC), reconocido por su elevada área superficial y abundancia de microporos, características que favorecen la adsorción de moléculas orgánicas mediante interacciones físicas y químicas. El empleo de carbón activado constituye una de las tecnologías más consolidadas para la eliminación de contaminantes orgánicos persistentes, permitiendo reducir la carga química residual antes de la descarga o reutilización del agua tratada [18].

Módulo 6. Remoción de hidrocarburos y aceites

Diseñado para retener hidrocarburos, aceites y grasas que puedan incorporarse al efluente debido al funcionamiento de maquinaria minera o actividades de mantenimiento. Se propone una combinación de organoclay, materiales oleofílicos y carbón activado, donde la arcilla modificada incrementa su afinidad por compuestos orgánicos no polares, mientras que los materiales oleofílicos favorecen la captura física de aceites libres. El carbón activado complementa el proceso mediante la adsorción de hidrocarburos disueltos de menor tamaño molecular. La utilización conjunta de estos medios permite ampliar el espectro de contaminantes removidos y disminuir el riesgo de transferencia de compuestos orgánicos hacia las etapas finales del tratamiento [18].

C. Aplicación de IA y Machine Learning

SenseCaps incorpora una plataforma analítica que complementa el control determinístico del PLC en cinco etapas: adquisición, transmisión, procesamiento, inferencia predictiva y visualización. Los registros multivariados del influente se transmiten por Wi Fi, LoRaWAN o 4G/LTE según la cobertura requerida hacia un servidor FastAPI, cuya arquitectura asíncrona ASGI atiende flujos concurrentes de telemetría sin bloqueo mientras la validación mediante esquemas Pydantic filtra lecturas anómalas [20]. Un pipeline de preprocesamiento mitiga el ruido de alta frecuencia con ventana móvil sobre ΔP y ΔJ, preservando los picos informativos [21] y normaliza las variables al rango 0 a 1 mediante escalamiento Min Max [22].

El componente predictivo central es un Random Forest Regressor, seleccionado por su balance entre robustez con datos limitados y bajo costo de inferencia en Edge, ensamblado de árboles entrenados por bagging con selección aleatoria de características, lo que correlaciona los árboles y confiere robustez frente al sobreajuste [23]. En aplicaciones comparables de calidad de agua y mantenimiento industrial, el modelo alcanza coeficientes de determinación entre 0,868 y 0,99 y reducciones del error cuadrático medio superiores al 60 por ciento frente a regresiones lineales, con latencias de inferencia inferiores al milisegundo [24]- [21]. La importancia por permutación aporta una capa explicable que sustenta el aislamiento de módulos [23]- [24].

El entrenamiento utilizará una estrategia de ventana deslizante para construir representaciones temporales de las variables de entrada y sus correspondientes variables objetivo, generando conjuntos de entrenamiento, validación y prueba en proporción 60, 30 y 10 %, respectivamente, con partición cronológica para evitar fuga de información [21]-[22]. Los hiper parámetros del modelo se ajustan mediante validación cruzada anidada, complementada con estimaciones fuera de bolsa para evaluar la capacidad de generalización del ensamble [23]-[24].

Como aún no existen datos reales de planta ni ensayos de banco, SenseCaps utilizará inicialmente datos sintéticos y simulados. Estos se generarán mediante un modelo de colmatación de filtros, simulaciones de Monte Carlo para representar distintas calidades de influente y la incorporación de ruido y variaciones bruscas, buscando reproducir condiciones reales de operación y evaluar el comportamiento del sistema.

La quinta etapa es la capa de supervisión e interacción, implementada mediante un dashboard en React y Material UI. Integra indicadores en tiempo real de calidad del agua, estaciones y módulos filtrantes, con análisis temporales, alertas y estimaciones de vida útil. Además, presenta recomendaciones de Random Forest e IA generativa. El flujo comprende sensores, PLC/Edge, comunicación, Firestore, FastAPI, preprocesamiento, Random Forest, IA generativa y dashboard. [20]-[22].

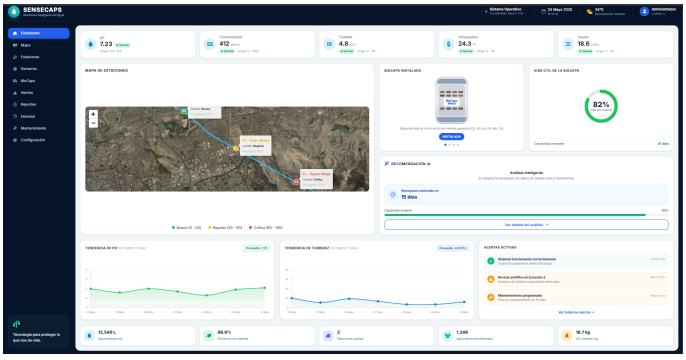


Fig. 3 Dashboard Software SenseCaps

SenseCaps utiliza reglas determinísticas para decidir qué módulos de tratamiento activar o aislar, basándose en umbrales validados, evitando decisiones no auditables. El aprendizaje automático se reserva para estimar variables de desgaste y mantenimiento.

III. Resultados Esperados

Con base en la revisión de la literatura y en el sistema adaptativo propuesto, se espera que SenseCaps contribuya a mejorar la eficiencia del tratamiento de efluentes provenientes

de la minería del cobre mediante una estrategia de filtración adaptativa capaz de seleccionar dinámicamente los módulos de tratamiento según las características del agua.

Asimismo, se espera optimizar el uso de los medios filtrantes, reducir su desgaste y disminuir los costos de mantenimiento mediante estrategias de monitoreo continuo y mantenimiento predictivo, favoreciendo una mayor continuidad operacional del sistema.

Finalmente, se espera que el monitoreo en tiempo real y el análisis inteligente de los datos apoyen la toma de decisiones operativas, contribuyendo a una gestión más eficiente y sostenible del recurso hídrico en la industria minera. Como trabajo futuro, se plantea la implementación y validación experimental del sistema en un entorno piloto para evaluar su desempeño bajo condiciones reales de operación y cuantificar los beneficios obtenidos frente a sistemas convencionales.

IV. Conclusión

El presente trabajo describe SenseCaps, un sistema de tratamiento adaptativo orientado a efluentes generados por la minería del cobre, cuya arquitectura integra herramientas para la selección dinámica de módulos filtrantes.

A diferencia de los trenes de filtración convencionales de configuración fija, la propuesta permite activar únicamente los módulos requeridos según las características fisicoquímicas del agua, lo que reduce el desgaste innecesario de los medios filtrantes y optimiza los costos asociados al mantenimiento de cartuchos, aspectos que, de acuerdo con la literatura revisada, representan una fracción significativa del costo operacional en la industria minera.

De este modo, SenseCaps integra tres elementos diferenciadores integrados, una arquitectura hidráulica modular y reconfigurable, separa las reglas determinísticas para seguridad del ML para eficiencia operacional y combina medios de tratamiento específicos para abordar simultáneamente Cu, As y Al presentes en efluentes de la minería del cobre andina.

Referencias

[1] Comisión Chilena del Cobre (Cochilco), "Observatorio de Costos Cochilco 2025 vs. 2024," Cochilco, Santiago, Chile, May 2026. [Online]. Available: https://www.cochilco.cl/web/observatorio-de-costos-cochilco-reporte-2025-vs-2024/

[2] Nordstrom, D. K. (2011). Mine waters: Acidic to circumneutral. Elements, 7(6), 393–398. https://doi.org/10.2113/gselements.7.6.393

[3] Ning, S., & Hong, S. (2021). Programmable logic controller-based automatic control for municipal wastewater treatment plant optimization. Water Practice & Technology. https://doi.org/10.2166/wpt.2021.121

[4] Ren, J., Zhu, Q., & Wang, C. (2022). Edge computing for water quality monitoring systems. Mobile Information Systems, 2022, Article 5056606, 1–7. https://doi.org/10.1155/2022/5056606

[5] Ruiz-García, A., & Feo-García, J. (2017). Operating and maintenance cost in seawater reverse osmosis desalination plants. Artificial neural network based model. Desalination and Water Treatment, 73, 73–79.

[6] Dumitru, P.-P., Florescu, C., Girbaciu, A., & Vâju, D. (2020). The Technologies Optimization for the Treatment of Underground Water with Iron and Arsenic Content – A Case Study. IOP Conference Series: Materials Science and Engineering.

[7] Adelman, M. J., Oberoi, P., Glover, C. M., Waite, A., Wang, S., Oppenheimer, J., & Jacangelo, J. G. (2025). Multiple benefits of MBR and absolute-rated cartridge filters for RO pretreatment: Results from a full-scale facility. Water Reuse, 15(2), 142–156.

[8] Ochieng, G. M. M., Otieno, F. A. O., Ogada, T. P. M., Shitote, S. M., & Menzwa, D. M. (2004). Performance of multistage filtration using different filter media against conventional water treatment systems. Water SA, 30(3)

[9] Souza, F. C., et al. (2026). High-rate depth filtration of produced water: Systematic media screening based on performance, backwash and fouling behavior. Separation and Purification Technology, 405(138982). https://doi.org/10.1016/j.seppur.2026.138982

[10] Tobiason, J. E., Edzwald, J. F., et al. (2018). Granular Media Filtration. En Water Quality and Treatment: A Handbook on Drinking Water (7th ed.). https://doi.org/10.1002/9781119314847.ch8

[11] Cravotta III, C. A. (2003). Size and performance of anoxic limestone drains to neutralize acidic mine drainage. Journal of Environmental Quality, 32, 1277–1289. https://doi.org/10.2134/jeq2003.1277

[12] Santomartino, S., & Webb, J. A. (2007). Estimating the longevity of limestone drains in treating acid mine drainage containing high concentrations of iron. Applied Geochemistry, 22(11), 2344–2361. https://doi.org/10.1016/j.apgeochem.2007.07.009

[13] Fu, F., & Wang, Q. (2011). Removal of heavy metal ions from wastewaters: A review. Journal of Environmental Management, 92(3), 407–418. https://doi.org/10.1016/j.jenvman.2010.11.011

[14] Inyang, M., Gao, B., Yao, Y., Xue, Y., Zimmerman, A., Mosa, A., Pullammanappallil, P., Ok, Y. S., & Cao, X. (2012). Removal of heavy metals from aqueous solution by biochars derived from anaerobically digested biomass. Bioresource Technology, 110, 50–56. https://doi.org/10.1016/j.biortech.2012.01.072

[15] Mohan, D., & Pittman, C. U. Jr. (2007). Arsenic removal from water/wastewater using adsorbents—A critical review. Journal of Hazardous Materials, 142(1–2), 1–53. https://doi.org/10.1016/j.jhazmat.2007.01.006

[16] Jang, M., Chen, W., & Bishop, P. L. (2005). Adsorptive removal of arsenate using hydrous iron oxide-coated media. Water Research, 39, 2949–2957. https://doi.org/10.1016/j.watres.2005.04.003

[17] Bansal, R. C., & Goyal, M. (2005). Activated Carbon Adsorption. CRC Press. https://doi.org/10.1201/9781420028815

[18] Carmody, O., Frost, R., Xi, Y., & Kokot, S. (1998). Adsorption of hydrocarbons on organoclays. Chemosphere, 37, 1807–1818. https://doi.org/10.1016/S0045-6535(98)00208-8

[19] Mabotha, E., Mabunda, N. E., Ali, A., & Khan, B. (2025). A Dockerized approach to dynamic endpoint management for RESTful application programming interfaces in Internet of Things ecosystems. Sensors, 25(10), 2993.

[20] Said, I. (2026). Machine learning for water quality management: a systematic review of prediction models, data challenges, and future directions. Environmental Sciences Europe, 38(1), 136.

[21] Zhu, Y., Wang, Y., Zhu, E., Ma, Z., Wang, H., Chen, C., Guan, J., & Waite, T. D. (2024). Predicting membrane fouling of submerged membrane bioreactor wastewater treatment plants using machine learning. UNSW Sydney / Beijing Origin Water.

[22] Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32.

[23] Rosati, R., Romeo, L., Cecchini, G., Tonetto, F., Viti, P., Mancini, A., & Frontoni, E. (2023). From knowledge-based to big data analytic model. Journal of Intelligent Manufacturing, 34(1), 107–121.

[24] Dharmarathne, G., Perera, S., & Yapa, P. (2025). Machine learning in water quality evaluation. Results in Engineering, 26, 105182.