ConBRepro
XVI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
EVENTO ON-LINE
02 a 04 de dezembro de 2026
Inovação e Transformação Digital como Estratégia Competitiva nas Engenharias

A utilização da inteligência artificial no tratamento de efluentes: novas oportunidades

Giovanna Gonçalves
PPGEP – UTFPR
Angelo Marcelo Tusset
PPGEP – UTFPR

Resumo: O tratamento de efluentes é um processo complexo, dinâmico e altamente não-linear, o que impõe desafios significativos para a manutenção da eficiência operacional e sustentabilidade ambiental. Este artigo analisa as novas oportunidades geradas pela integração da Inteligência Artificial (IA) nas Estações de Tratamento de Esgoto (ETEs). A partir de uma revisão de literatura fundamentada em pesquisas recentes (2016-2025), o estudo investiga a aplicação de algoritmos de *Machine Learning* (ML) e *Deep Learning* (DL) na modelagem preditiva, otimização de processos, detecção de falhas e no desenvolvimento de Gêmeos Digitais (*Digital Twins*). Os resultados apontam que o uso de "sensores virtuais" (*soft sensors*) e sistemas de controle baseados em IA reduzem os custos operacionais (especialmente o consumo de energia) e aumentam a precisão na previsão de parâmetros de qualidade, como DQO e DBO. Contudo, a qualidade dos dados gerados por sensores físicos continua sendo o principal obstáculo para a implementação em larga escala. Conclui-se que a IA é essencial para a transformação das ETEs tradicionais para as futuras *smart water grids* (redes inteligentes de água).

Palavras-chave: Inteligência Artificial; Tratamento de Efluentes; Modelagem Preditiva; Indústria 4.0;

The use of artificial intelligence in wastewater treatment: new opportunities

Abstract: Wastewater treatment is a complex, dynamic, and highly non-linear process, posing significant challenges for maintaining operational efficiency and environmental sustainability. This article analyzes the new opportunities arising from the integration of Artificial Intelligence (AI) into Wastewater Treatment Plants (WWTPs). Based on a literature review of recent research (2016–2025), the study investigates the application of Machine Learning (ML) and Deep Learning (DL) algorithms in predictive modeling, process optimization, fault detection, and the development of Digital Twins. The results indicate that the use of "soft sensors" and AI-based control systems reduces operational costs (particularly energy consumption) and improves the accuracy of predicting quality parameters, such as COD and BOD. However, the quality of data generated by physical sensors remains the primary obstacle to large-scale implementation. The study concludes that AI is essential for transforming traditional WWTPs into future smart water grids.

Keywords: Artificial Intelligence; Wastewater Treatment; Predictive Modeling; Industry 4.0;

1.0 Introdução

As Estações de Tratamento de Esgoto (ETEs) desempenham um papel importante na proteção da saúde pública e na diminuição da poluição hídrica. No entanto, essas instalações enfrentam pressões crescentes devido ao rigor das regulamentações ambientais, ao aumento populacional e aos impactos das mudanças climáticas, que causam extrema variabilidade nas vazões e cargas poluidoras (BASSIN *et al.*, 2021; RANIERI *et al.*, 2024). Tradicionalmente, as ETEs são operadas com base em cálculos fixos e sistemas que só reagem aos problemas. Porém, essas abordagens antigas costumam falhar, pois não conseguem acompanhar as mudanças rápidas e imprevisíveis das reações químicas e biológicas do esgoto (WANG *et al.*, 2021).

Nesse contexto de limitação dos sistemas convencionais, a Indústria 4.0 introduziu a digitalização no setor de saneamento (DE LA HOZ-M *et al.*, 2024). A Inteligência Artificial (IA), englobando *Machine Learning* (ML) e *Deep Learning* (DL), surgiu como uma ferramenta poderosa para transformar grandes volumes de dados operacionais em *insights* acionáveis (ZHANG *et al.*, 2022; MIR JUNAID, 2025). No âmbito da Engenharia de Produção, a convergência dessas tecnologias digitais consolida a transição da gestão ambiental puramente corretiva para o paradigma da Indústria 4.0, focado na prevenção e na eco-inovação. A integração de Sistemas Ciber-Físicos (CPS) e da Internet das Coisas (IoT) nas plantas de tratamento cria a infraestrutura de dados necessária para que os algoritmos de IA operem de maneira contínua (DE LA HOZ-M; ARIZA-ECHEVERRI; VERGARA, 2024). Essa tecnologia transforma as antigas estações isoladas em sistemas inteligentes e conectados. Agora, elas conseguem se adaptar de forma automática às oscilações da água que entra, otimizando os custos e o gasto de energia de toda a planta. (GERNAEY *et al.*, 2023).

Esses desafios tornam-se ainda mais críticos quando se aborda o tratamento de efluentes industriais complexos. A crescente presença de contaminantes emergentes nas matrizes aquosas, como compostos farmacêuticos e estimulantes estruturalmente estáveis (a exemplo da cafeína), exige o emprego de processos avançados de tratamento cujas variáveis operacionais são difíceis de adequar manualmente. Além disso, o controle dessas estações afeta diretamente a redução de riscos e a segurança operacional das plantas. O presente artigo tem como objetivo explorar as novas oportunidades oferecidas pela IA no tratamento de efluentes, avaliando sua eficácia na previsão da qualidade da água, otimização de processos avançados, eficiência energética e na criação de infraestruturas resilientes (MAMANDIPOOR *et al.*, 2020).

2. Metodologia

Este estudo caracteriza-se como uma revisão bibliográfica narrativa e integrativa. A metodologia consistiu na seleção e análise de 20 artigos científicos internacionais, publicados entre 2016 e 2025.

Seleção de Dados: A pesquisa priorizou periódicos de excelência nas áreas de engenharia ambiental, gestão de recursos hídricos e ciência da computação (ex: *Water Research*, *Science of the Total Environment*, *Bioresource Technology*). O processo de triagem seguiu as diretrizes de metodologias rigorosas de ranqueamento científico (*Methodi Ordinatio* e protocolo PRISMA) para assegurar uma base teórica robusta.

Critérios de Análise: Os artigos foram categorizados de acordo com sua aplicação principal: (1) previsão de qualidade do efluente; (2) controle e otimização energética; (3) detecção de falhas; e (4) gestão de dados e novas tecnologias estruturais (*Digital Twins*). A análise focou em extrair os benefícios quantificáveis e as limitações práticas apontadas pelos autores, sintetizando as tendências do estado da arte.

A Figura 1 ilustra o fluxo metodológico proposto para a implementação efetiva de Inteligência Artificial (IA) em uma Estação de Tratamento de Esgoto (ETE). O processo está estruturado de forma linear e sequencial, compreendendo quatro etapas fundamentais, que cobrem desde a preparação da infraestrutura até a aplicação operacional:

- Etapa 1 - Aquisição de Dados (ETE Física): O fluxo tem início no ambiente físico da planta de tratamento. Esta fase consiste na coleta contínua de parâmetros operacionais essenciais, utilizando sensores online de pH, oxigênio dissolvido, medidores de vazão e sensores de temperatura. Estes dados brutos formam a base para as etapas subsequentes.
- Etapa 2 - Pré-processamento: A segunda fase é crítica para garantir a qualidade dos modelos de IA. Os dados brutos provenientes da Etapa 1 são submetidos a um rigoroso tratamento de limpeza. Isso envolve a eliminação de erros de leitura dos sensores (remoção de ruídos e *outliers*) e o tratamento ou eliminação de dados ausentes, prevenindo vieses e distorções no treinamento (COROMINAS *et al.*, 2018).
- Etapa 3 - Treinamento do Modelo (A Inteligência): Com a base de dados consolidada e limpa, a terceira etapa foca no desenvolvimento da capacidade analítica do sistema. Nesta fase, ocorre a aplicação de dados históricos em conjunto com algoritmos de *Machine Learning* e/ou *Deep Learning* para que o modelo aprenda os padrões complexos de tratamento e as relações não lineares entre as variáveis físico-químicas.
- Etapa 4 - Aplicação em Tempo Real: A etapa final representa a integração do modelo treinado à operação contínua da ETE. O sistema passa a monitorar e prever parâmetros de saída, atuando como *soft sensors* para a previsão da DBO (Demanda Bioquímica de Oxigênio) de saída, detecção de falhas operacionais e, em última instância, fornecendo inteligência para a automação do controle de equipamentos críticos, como bombas e sopradores.

Figura 1 - Fluxo de implementação de IA em uma Estação de Tratamento de Esgoto

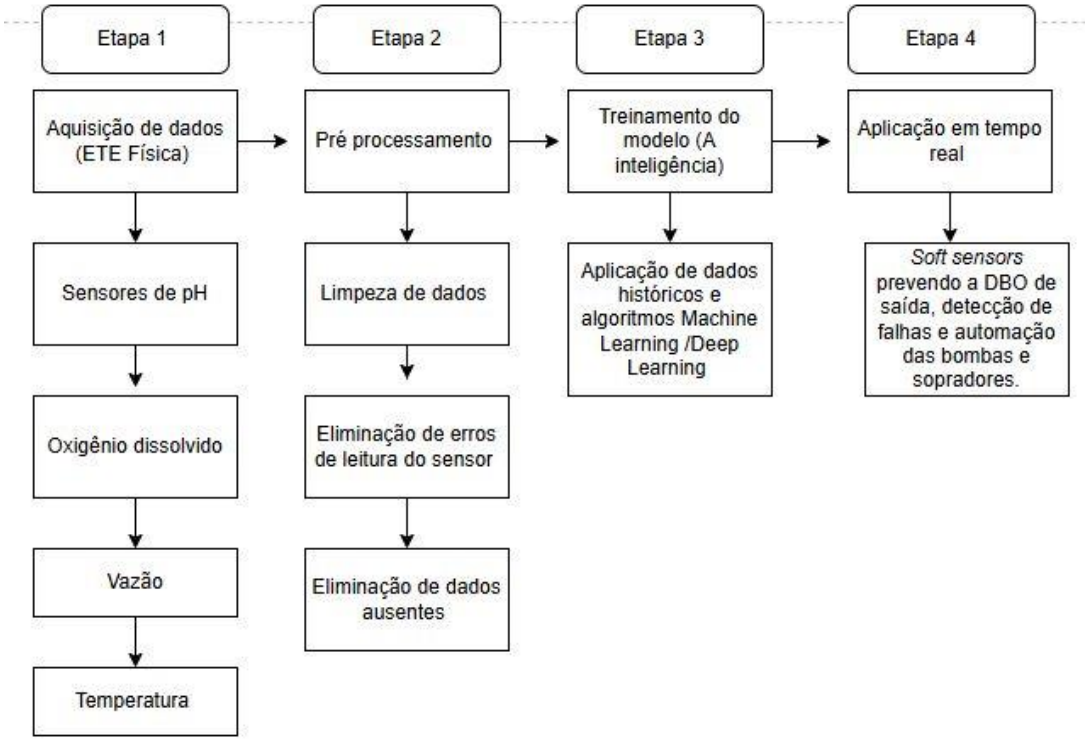

Fonte: Autoria Própria (2026)

3.0 Referencial Teórico

A aplicação de IA em ETEs baseia-se na capacidade dos algoritmos de aprenderem padrões a partir de dados históricos sem a necessidade de equações físicas ou biológicas explícitas. A digitalização ampliou drasticamente as frentes de atuação dessas tecnologias computacionais, dividindo-se em diferentes etapas operacionais.

3.1 Modelagem Preditiva e Sensores Virtuais (Soft Sensors)

A medição em tempo real de parâmetros como Demanda Química de Oxigênio (DQO) e Demanda Bioquímica de Oxigênio (DBO) é custosa e sujeita a atrasos laboratoriais. Redes Neurais Artificiais (ANN), Redes de Regressão Generalizada e Redes Wavelet têm sido amplamente utilizadas para criar *soft sensors*, estimando esses parâmetros quase em tempo real a partir de variáveis de fácil medição, como pH, temperatura e oxigênio dissolvido (CONG; YU, 2018; HEDDAM *et al.*, 2016).

3.2 IA na Otimização de Processos Avançados e Eco-inovação

Além dos sistemas convencionais de lodos ativados, a modelagem via IA tem otimizado processos sustentáveis de eco-inovação, como a valorização de resíduos agrícolas. A aplicação de biossorventes, como a funcionalização química de *biochar* derivado de casca de coco para a adsorção de cafeína em soluções aquosas, gera grandes e complexas matrizes de dados (ZHU *et al.*, 2021). Nesses casos, algoritmos preditivos modelam as isotermas e preveem com alta precisão a capacidade máxima de adsorção e as curvas de ruptura tanto em ensaios de batelada quanto em sistemas de fluxo contínuo.

Da mesma forma, a eficiência dos Processos Oxidativos Avançados (POAs), como a Oxidação Catalítica por Peróxido de Hidrogênio (CWPO) e os processos Fenton heterogêneos, tem sido alavancada pela IA. Tais processos frequentemente utilizam catalisadores baseados em metais de transição (nióbio, ferro, cobre, manganês ou cobalto) ancorados em suportes de carbono. A dinâmica reacional é altamente sensível; a IA permite prever a dosagem estequiométrica ideal do peróxido de hidrogênio e a estabilidade do catalisador (prevenindo a lixiviação metálica), assegurando a geração maximizada de radicais hidroxila para a degradação de compostos recalcitrantes, minimizando assim os custos operacionais (MIR JUNAID, 2025).

3.3 Controle, Otimização e Segurança Operacional

Técnicas avançadas, como Redes Neurais Fuzzy Recorrentes e Aprendizado por Reforço Profundo (*Deep Reinforcement Learning*), permitem ajustar dinamicamente as operações da planta, como a taxa de aeração e o descarte de lodo, otimizando o processo frente a perturbações dinâmicas (QIAO *et al.*, 2019; MOHAMMADI, 2025). Simultaneamente, a aplicação de aprendizado não supervisionado provou ser altamente eficaz na identificação de padrões anômalos que indicam toxicidade no afluente, acúmulo perigoso de gases ou falhas de equipamentos (DAIRI *et al.*, 2019). A predição dessas falhas translada a IA para o campo da segurança ocupacional, permitindo atuar de maneira preventiva na mitigação de riscos de acidentes de trabalho em plantas químicas e na proteção de trabalhadores em espaços confinados (MAMANDIPOOR *et al.*, 2020).

3.4 Digital Twins (Gêmeos Digitais)

Esta tecnologia representa a fronteira tecnológica atual. Consiste em uma réplica virtual da ETE que, alimentada por IA e dados em tempo real, permite simular cenários extremos de

carga orgânica e testar estratégias de controle e segurança sem risco físico ou operacional para a planta real (AZIZ *et al.*, 2024; GERNAEY *et al.*, 2023). Algoritmos como as redes de Memória de Longo Curto Prazo (*LSTM*), demonstram superioridade nesta modelagem preditiva, antecipando o comportamento sistêmico da planta (ZHANG *et al.*, 2022).

O Quadro 1 descreve as principais IA nas ETEs, com base nas referências discutidas.

Quadro 1 - Principais aplicações de algoritmos de Inteligência Artificial no tratamento de efluentes

Etapa / Desafio na ETE	Parâmetro alvo	Algoritmos de IA mais comuns	Oportunidades observadas	Referência base
Previsão de Qualidade do Efluente	DQO, DBO, SST, Nitrogênio Total, Fósforo	DQO, DBO, SST, Nitrogênio Total, Fósforo	Substitui análises laboratoriais demoradas por medições virtuais em tempo real (*soft sensors*); prevê violações de limites de descarte.	Hamada et al. (2024); Cong & Yu (2018)
Otimização Energética	Consumo de energia nos sopradores (Tanque de Aeração)	Reinforcement Learning (RL), Sistemas Neuro-Fuzzy	Ajuste dinâmico da injeção de oxigênio de acordo com a carga orgânica, reduzindo o custo energético em até 20-30%.	Qiao et al. (2019); Ranieri et al. (2024)
Detecção de Falhas e Anomalias	Sensores sujos, eventos de toxicidade, estufamento do lodo (bulking)	Support Vector Machines (SVM), Aprendizado Não-Supervisionado (PCA, Autoencoders)	Isolamento rápido de sensores defeituosos; alerta precoce sobre mortandade da biomassa por compostos tóxicos industriais.	Dairi et al. (2019); Mamandipoor et al. (2020)
Gestão e Controle Integrado	Simulação de cenários climáticos extremos e picos de vazão	Digital Twins, Modelos Híbridos (IA + Modelos Mecanicistas)	Criação de "Gêmeos Digitais" da ETE para treinamento de operadores e testes de estresse sem colocar a planta física em risco.	Aziz et al. (2024); Gernaey et al. (2023)

Autoria Própria (2026)

Para capturar a dinâmica temporal e as flutuações não-lineares típicas dos afluentes, arquiteturas avançadas de *Deep Learning* ganharam destaque na literatura recente (ZHANG *et al.*, 2022). Algoritmos como as Redes Neurais Recorrentes (RNN) e, especificamente, as redes de Memória de Longo Curto Prazo (*Long Short-Term Memory* - LSTM), demonstram superioridade na previsão de séries temporais ao reterem informações de eventos passados. Essa capacidade de "memória" permite que o modelo antecipe comportamentos futuros da planta com base em tendências históricas complexas de vazão e carga orgânica, superando as limitações dos modelos estáticos tradicionais (QIAO *et al.*, 2019; HAMADA *et al.*, 2024).

Adicionalmente, a IA tem se mostrado promissora na otimização de processos de tratamento mais severos, como os Processos Oxidativos Avançados (POAs). Em sistemas complexos que utilizam catalisadores metálicos e agentes oxidantes para a degradação de efluentes industriais, os algoritmos de *Machine Learning* podem modelar a cinética de reação e prever a dosagem ótima de reagentes (ALIZAMIR *et al.*, 2024). Isso maximiza a geração de radicais e minimiza o desperdício de insumos químicos, garantindo a estabilidade do processo e a degradação eficiente de substancias recalcitrantes (MIR JUNAID, 2025).

4. Resultados

A análise bibliométrica e teórica da literatura revela que a transição de um paradigma reativo para um preditivo nas ETEs já é uma realidade viabilizada pela IA. Os impactos positivos relatados nos estudos concentram-se em três eixos principais: precisão operacional, eficiência de recursos e segurança estrutural.

4.1. Acurácia Preditiva e Otimização de Processos Avançados Modelos de *Machine Learning*

Os dados têm demonstrado excepcional precisão (frequentemente com coeficientes de correlação $R^2 > 0.90$) na previsão de efluentes finais a partir de variáveis de entrada dinâmicas (HAMADA *et al.*, 2024; ALIZAMIR *et al.*, 2024). Além disso, os resultados da literatura indicam que a modelagem de conjunto (*ensemble modeling*) não apenas aumenta a confiabilidade dessas previsões, mitigando a variância dos modelos individuais (NOURANI *et al.*, 2018), mas também apresenta resultados expressivos na otimização de processos baseados em eco-inovação.

Na valorização de resíduos agrícolas para a produção de materiais avançados — como a funcionalização química de *biochar* de casca de coco —, os algoritmos provaram ser altamente capazes de prever a capacidade máxima de adsorção de contaminantes emergentes (como a cafeína) em matrizes aquosas complexas. Esses modelos reduzem o número de ensaios laboratoriais necessários, otimizando as curvas de ruptura em sistemas de batelada e fluxo contínuo. Adicionalmente, na aplicação de Processos Oxidativos Avançados (POAs), especificamente a Oxidação Catalítica por Peróxido de Hidrogênio (CWPO), os resultados mostram que as redes neurais otimizam com sucesso a geração de radicais hidroxila. A IA atua prevendo a dosagem ótima de peróxido e monitorando a estabilidade de catalisadores heterogêneos baseados em metais de transição (como cobre, ferro, manganês e nióbio) suportados em carbono, o que reduz drasticamente o consumo de reagentes e aumenta a taxa de degradação da matéria orgânica recalcitrante (MIR JUNAID, 2025).

4.2. Redução de Custos e Monitoramento em Tempo Real

No que tange aos custos de operação, a aeração em processos de lodos ativados pode consumir até 60% da energia total de uma ETE. Estudos demonstram que sistemas de IA acoplados a inversores de frequência podem otimizar o fornecimento de oxigênio quase em tempo real, ajustando a potência dos sopradores de acordo com as flutuações da carga orgânica aferida pelos *soft sensors*. Essa automação gera uma altíssima relação custo-benefício e reduz significativamente a pegada de carbono das instalações (SINGH *et al.*, 2023; RANIERI *et al.*, 2024). O uso de algoritmos de *Deep Learning* para monitoramento ininterrupto também reduziu o tempo de resposta a falhas biológicas, como o estufamento de lodo (*bulking*), prevenindo paradas operacionais e multas ambientais por descarte fora dos padrões regulatórios (ZHU *et al.*, 2021).

4.3. Inteligência Artificial na Mitigação de Riscos e Segurança Ocupacional

Os resultados também evidenciam o papel central da IA na evolução das diretrizes de segurança ocupacional dentro das plantas de tratamento e instalações químicas adjacentes. A literatura demonstra uma transição clara: de uma abordagem puramente reativa e corretiva para a modelagem preditiva de riscos. A capacidade dos algoritmos de reconhecimento de padrões não se limita aos parâmetros de qualidade da água, estendendo-se à detecção precoce de condições ambientais e operacionais perigosas, como o acúmulo de gases tóxicos em espaços confinados ou anomalias de pressão em reatores de circuito fechado (ZHU *et al.*, 2021).

Essa predição automatizada transforma a segurança do trabalho no ambiente industrial, reduzindo drasticamente a exposição direta dos operadores a agentes nocivos e estressores físicos. Ao prever o colapso de equipamentos antes que ele ocorra, a IA previne acidentes severos por meio de alertas integrados diretamente aos sistemas de supervisão e intertravamento automático das plantas (MAMANDIPOOR *et al.*, 2020).

5. Desafios da Implementação

Embora os estudos mostrem o grande potencial da Inteligência Artificial, o seu uso prático e em larga escala nas Estações de Tratamento de Esgoto (ETEs) ainda não é simples. Para que essas soluções funcionem no dia a dia do setor, será preciso superar importantes obstáculos tecnológicos, operacionais e culturais.

5.1. O Desafio Crítico da Qualidade de Dados

Todos os estudos concordam em um ponto importante: a Inteligência Artificial só funciona bem se receber dados de boa qualidade (COROMINAS *et al.*, 2018). Nas plantas de saneamento, os sensores físicos operam em ambientes quimicamente agressivos e estão sujeitos à bio-incrustação e descalibração contínua. Sensores sujos geram dados ruidosos e *outliers* que, se alimentarem diretamente a rede neural, produzirão previsões equivocadas (*garbage in, garbage out*). Portanto, reunir as rotinas rigorosas de gestão da qualidade dos dados (filtração algorítmica de ruídos, imputação estatística de dados ausentes) é um pré-requisito absoluto antes de qualquer aplicação em ETEs (COROMINAS *et al.*, 2018).

5.2. Gestão de Riscos e Treinamento para Eventos Raros

Outro desafio técnico reside na modelagem de anomalias críticas. A maioria dos conjuntos de dados operacionais disponíveis reflete o funcionamento normal da planta. Treinar modelos de *Machine Learning* para prever eventos catastróficos raros — como picos repentinos de toxicidade severa ou vazamento de gases asfixiantes em espaços confinados — requer técnicas sofisticadas de aumento de dados (*data augmentation*) ou detecção de novidades. Sem essa robustez, a promessa da IA de auxiliar na prevenção de acidentes de trabalho torna-se vulnerável.

5.3. O Dilema da Interpretabilidade e Aceitação Cultural

A literatura ressalta também que a adoção dessas ferramentas esbarra no desafio da interpretabilidade. Como muitos algoritmos de *Deep Learning* funcionam como "caixas pretas" puramente matemáticas, há uma resistência natural por parte de operadores e engenheiros em confiar de maneira cega em decisões automatizadas críticas, como alterações na dosagem química de reatores ou na desativação de alarmes (COROMINAS *et al.*, 2018). Para reduzir essa resistência, faz-se mandatório o avanço da Inteligência Artificial Explicável (*Explainable AI* - XAI), capaz de traduzir a lógica matemática subjacente em regras operacionais claras e transparentes (ZHANG *et al.*, 2022).

6. Conclusões

O uso da Inteligência Artificial no tratamento de efluentes deixou de ser apenas um conceito teórico para se tornar uma necessidade operacional tangível. As oportunidades proporcionadas por ferramentas como *soft sensors*, algoritmos de controle preditivo e Gêmeos Digitais estão revolucionando a forma como as ETEs operam, garantindo maior resiliência climática, economia de energia e cumprimento rigoroso dos padrões de lançamento ambiental.

Conclui-se que a IA atua como uma ponte estratégica entre a eficiência ambiental e a segurança ocupacional. Ao utilizar a Inteligência Artificial para antecipar cenários — seja melhorando tratamentos químicos difíceis como a eliminação de poluentes resistentes ou prevendo falhas nos equipamentos antes que elas aconteçam, a IA desloca a gestão industrial de uma abordagem reativa de correção de danos para um modelo preditivo de

mitigação de riscos. Entretanto, para que a adoção dessas tecnologias alcance seu potencial máximo em escala industrial, o setor deve superar os obstáculos da infraestrutura de IoT, a instabilidade na qualidade de dados de sensores de campo e a opacidade algorítmica dos modelos complexos.

Ao integrar essas inovações, o setor caminha para uma mudança estrutural onde as ETEs se consolidam como biorrefinarias e polos de eco-inovação — exemplificados pela valorização inteligente de resíduos para a produção de biossorventes avançados. A Inteligência Artificial atua, assim, como o núcleo dessa transformação tecnológica, orquestrando processos e alinhando o tratamento de efluentes aos pilares da economia circular.

Por fim, recomenda-se que o avanço contínuo dessa área seja direcionado por metodologias de pesquisa estruturadas. A evolução acelerada das tecnologias da Indústria 4.0 exige que a comunidade científica continue a utilizar protocolos sistemáticos e ferramentas de ranqueamento, como o PRISMA, para mapear o estado da arte com rigor e precisão, garantindo a transferência de soluções acadêmicas robustas para a complexa realidade industrial.

Referências

ALIZAMIR, M. *et al.* Artificial intelligence techniques for predicting effluent quality in wastewater treatment plants: A critical review. **Water Research**, v. 249, p. 120935, 2024.

AZIZ, A. *et al.* Digital twins for real-time monitoring of wastewater collection systems during severe weather. **Water Research**, v. 250, p. 120999, 2024.

BASSIN, J. P. *et al.* The impact of climate change on wastewater treatment plants and AI adaptation strategies. **Journal of Cleaner Production**, v. 312, p. 127718, 2021.

CONG, Y.; YU, J. A mixed soft sensor model based on wavelet neural network for online prediction of effluent COD. **Chemosphere**, v. 200, p. 54-63, 2018.

COROMINAS, L. *et al.* Data quality management in wastewater treatment plants: A prerequisite for machine learning applications. **Water Research**, v. 137, p. 266-278, 2018.

DAIRI, A. *et al.* Unsupervised and deep learning for anomaly detection in wastewater treatment plants. **Engineering Applications of Artificial Intelligence**, v. 86, p. 17-29, 2019.

DE LA HOZ-M, J.; ARIZA-ECHEVERRI, E. A.; VERGARA, D. Exploring the Role of Artificial Intelligence in Wastewater Treatment: A Dynamic Analysis of Emerging Research Trends. **Resources**, v. 13, n. 12, p. 171, 2024.

GERNAEY, K. V. *et al.* Moving towards smart water grids: The role of digital twins and AI in modern wastewater infrastructure. **Environmental Science: Water Research & Technology**, v. 9, n. 4, p. 980-995, 2023.

HAMADA, M. S. *et al.* Using a supervised machine learning approach to predict water quality parameters in wastewater treatment plants. **RSC Advances**, v. 14, p. 132-145, 2024.

HEDDAM, S. *et al.* Generalized regression neural network model for BOD estimation in wastewater treatment. **Environmental Earth Sciences**, v. 75, n. 1, p. 1-13, 2016.

MAMANDIPOOR, B. *et al.* Fault identification in wastewater treatment plants using machine learning techniques. **Process Safety and Environmental Protection**, v. 143, p. 261-274, 2020.

MIR JUNAID, R. A Comprehensive Review of Machine Learning Applications in Wastewater Treatment. **Journal of Innovation and Technology**, v. 2025, n. 2, p. 1-18, 2025.

MOHAMMADI, E. **Modeling and Optimization of Wastewater Treatment Plants with Deep Reinforcement Learning**. Aalborg University Publications, 2025.

NOURANI, V. *et al.* AI-based ensemble modeling for wastewater treatment plant performance monitoring. **Journal of Environmental Management**, v. 227, p. 248-261, 2018.

QIAO, J. *et al.* A recurrent fuzzy neural network-based strategy for wastewater treatment control. **IEEE Transactions on Industrial Informatics**, v. 16, n. 5, p. 3233-3242, 2019.

RANIERI, E. *et al.* Climate variability and energy consumption in wastewater treatment: An AI modeling approach. **Desalination and Water Treatment**, v. 310, p. 100-112, 2024.

SINGH, A. *et al.* Cost-effectiveness of implementing AI in wastewater treatment: A global review. **Water Science and Technology**, v. 88, n. 3, p. 540-555, 2023.

WANG, H. *et al.* Uncertainties in wastewater treatment processes and AI-driven predictive control. **Chemical Engineering Journal**, v. 419, p. 129532, 2021.

ZHANG, K. *et al.* Machine learning for wastewater treatment process optimization: A comprehensive review. **Science of the Total Environment**, v. 834, p. 155319, 2022.

ZHU, M. *et al.* Real-time monitoring and fault detection in wastewater treatment plants using deep learning. **Bioresource Technology**, v. 337, p. 125439, 2021.