

INTELIGÊNCIA ARTIFICIAL APLICADA AO TRATAMENTO DE EFLUENTES: UMA REVISÃO DA PRODUÇÃO CIENTÍFICA INTERNACIONAL NOS ÚLTIMOS CINCO ANOS

MONIQUE SCHNEIDER SIMÃO

Mestranda em Engenharia de Produção, Universidade Federal do Paraná – UFPR, Brasil.
monique.schneidersimo@gmail.com

JOSÉ EDUARDO PÉCORA JUNIOR

Doutor em Administração de Empresas, Université Laval - Departamento de Operações e Sistemas de Decisão, Canadá.
Professor do Departamento de Administração Geral e Aplicada da Universidade Federal do Paraná – UFPR, Brasil.
pecora@ufpr.br

Resumo

O tratamento de efluentes domésticos e industriais é um processo complexo que ocorre empregando-se uma combinação de intervenções químicas, físicas e biológicas. Já a inteligência artificial (IA) consiste de diferentes métodos computacionais que visam simular os processos cognitivos dos seres humanos tais como a aprendizagem, o reconhecimento de padrões, a resolução de problemas entre outros. Este artigo de revisão sistemática foi elaborado para verificar quais técnicas de IA foram utilizadas e em quais problemas do tratamento de efluentes elas foram aplicadas. Após a análise da produção científica publicada nos últimos cinco anos, verificou-se que a inteligência artificial foi majoritariamente empregada no controle de processos biológicos de tratamento e que a técnica mais utilizada foram redes neurais nebulosas.

Palavras-chave: tratamento de efluentes, inteligência artificial.

ARTIFICIAL INTELLIGENCE APPLIED TO EFFLUENT TREATMENT: AN INTERNATIONAL SCIENTIFIC PRODUCTION REVIEW IN THE LAST FIVE YEARS

Abstract

Treatment of domestic and industrial wastewater is a complex process that occurs using a combination of chemical, physical and biological interventions. Artificial Intelligence (AI) consists of different computational methods that aim to simulate the cognitive processes of human beings such as learning, pattern recognition, problem solving, among others. This systematic review paper was designed to verify which AI techniques were used and in what wastewater treatment problems they were applied to. After analyzing the scientific production published in the last five years, it was found that AI was mostly used to control biological treatment processes and that the most used technique was fuzzy neural networks.

Keywords: wastewater treatment, artificial intelligence.

INTELIGENCIA ARTIFICIAL APLICADA AL TRATAMIENTO DE EFLUENTES: UNA REVISIÓN DE LA PRODUCCIÓN CIENTÍFICA INTERNACIONAL EN LOS ÚLTIMOS CINCO AÑOS

Resumen

El tratamiento de aguas residuales domésticas e industriales es un proceso complejo que ocurre usando una combinación de intervenciones químicas, físicas y biológicas. La inteligencia artificial (IA) ya consiste en diferentes métodos computacionales que tienen como objetivo simular los procesos cognitivos de los seres humanos, como el aprendizaje, el reconocimiento de patrones, la resolución de problemas, entre otros. Este artículo de revisión sistemática fue diseñado para verificar qué técnicas de IA se utilizaron y a qué problemas se aplicaron. Después de analizar la producción científica publicada en los últimos cinco años, se descubrió que la inteligencia artificial se usaba principalmente para controlar los procesos de tratamiento biológico y que la técnica más utilizada eran las redes neuronales nebulosas.

Palabras clave: tratamiento de efluentes, inteligencia artificial.

INTRODUÇÃO

O tratamento de efluentes domésticos e industriais é um processo complexo que ocorre empregando-se uma combinação de intervenções químicas, físicas e biológicas. Devido às regulamentações ambientais, que vêm se tornando cada vez mais restritas, as plantas de tratamento de efluentes estão sendo continuamente desafiadas a satisfazer novas restrições ambientais, além de manter a eficiência e os custos do processo. Para superar estas dificuldades, é imprescindível o uso de técnicas cada vez mais avançadas de controle e análise de processos (Xiao, Huang, Pan, Liu & Song, 2017).

Entre estas técnicas encontra-se a inteligência artificial, que consiste de diferentes métodos computacionais que visam simular os processos cognitivos dos seres humanos tais como a aprendizagem, o reconhecimento de padrões, a resolução de problemas entre outros.

O objetivo deste trabalho de revisão sistemática da literatura é realizar uma análise da produção científica publicada nos últimos cinco anos de forma a responder as seguintes questões:

- Quais técnicas de inteligência artificial foram utilizadas pelos autores no processo de tratamento de efluentes?
- Estas ferramentas foram empregadas para resolver qual tipo de problema?

Para tal, forneceremos um panorama estruturado sobre a aplicação da inteligência artificial no tratamento de efluentes, dividindo os artigos em seções que correspondem à técnica empregada, além de abordar brevemente os aspectos teóricos de cada uma destas ferramentas.

METODOLOGIA

A pesquisa foi realizada na base de dados *Web of Science* inserindo os seguintes termos na aba de pesquisa avançada: TI=(wastewater), onde TI significa o título do artigo, e aplicando-se em seguida os filtros: tipos de documento: article, anos de publicação: (2019 OR 2018 OR 2017 OR 2016 OR 2015 OR 2014), categorias do *Web of Science*: (COMPUTER SCIENCE ARTIFICIAL INTELLIGENCE) e índices: SCI-EXPANDED, SSCI, A&HCI, CPCI-S, CPCI-SSH, ESCI. No período entre 16 de setembro e 7 de outubro do ano de 2019. Esta pesquisa resultou em vinte artigos.

Foi também feita uma busca na base SCIELO/*Web of Science* com os termos em português: TS = (efluentes) AND TS= (inteligência artificial), onde TS significa tópico, sem limitação de categoria ou anos de publicação. Esta pesquisa não encontrou nenhum artigo.

REVISÃO DE LITERATURA

APRENDIZAGEM ESTATÍSTICA

Aprendizagem estatística trata da construção de modelos estatísticos que permitem extrair informações de um conjunto de dados ou que tornam possível estimar um resultado futuro. Dentre as ferramentas comumente empregadas podemos citar: (1) Cadeias de Markov - modelos que descrevem uma sequência de possíveis eventos, na qual a probabilidade de cada evento ocorrer depende apenas das condições do evento anterior; (2) Séries Temporais - utiliza modelos de análise de dados para identificar padrões e realizar previsões a partir de dados obtidos ao longo de um intervalo tempo; (3) Regressão - dentre os tipos existentes está a linear (uma variável independente) e a múltipla (duas ou mais variáveis independentes), que consistem em encontrar os coeficientes linear e angular, utilizando mínimos quadrados, da reta que melhor se ajustará ao conjunto de dados.

Zadorojniy, Wasserkrug, Zeltyn e Lipets (2019), visando uma melhora na eficiência e redução de custos operacionais nas plantas de tratamento de esgoto, construíram um modelo com a finalidade de realizar análise preditiva de comportamento, auxiliar nas tomadas de decisão e fornecer recomendações de melhoria. A matriz de transição de probabilidade foi utilizada na análise preditiva, em relação aos outros dois objetivos, foram testadas as abordagens de aprendizagem reforçada, regressão adaptativa multivariada (MARS) e cadeias de Markov (CMDP), sendo esta última a que obteve melhor desempenho. O modelo foi validado por meio de simulação (simulador BioWin), demonstrando uma redução no consumo de eletricidade, na quantidade de produtos químicos empregados na remoção de fósforo e no total de lama produzido.

Já Cheng, Wu, Liu e Huang (2019) conseguiram monitorar e detectar falhas incipientes, que tendem a ser encobertas por ruídos e distúrbios, utilizando métodos de análise de séries temporais e análise causal.

REDES NEURAIS

São algoritmos que mimetizam a forma com o cérebro funciona, consistem de neurônios artificiais interligados e agrupados em camadas. Cada ligação entre dois neurônios possui um peso e cada neurônio possui uma função de perda e um bias, que determina se ele será ativado ou não. Analisando-se as funções de perda de todos os neurônios em conjunto é possível construir uma função de perda global e determinar o desempenho da rede, caso este desempenho não seja satisfatório, novas iterações são feitas mudando-se os valores dos pesos das ligações e dos bias, até que a solução ótima seja obtida e os resultados das iterações converjam (Milidui, 1995).

Redes neurais podem ser associadas a conjuntos nebulosos na resolução de problemas de controle partindo apenas de um conjunto de dados de treinamento, sem que haja um modelo matemático pré-definido (Buckley & Hayashi, 1994). Conjuntos nebulosos foram definidos por Zadeh (1965) e são formados por objetos que não se distinguem tão claramente, sendo então caracterizados por uma função de associação que atribui a cada objeto um grau de pertinência ao conjunto que varia de zero a um. Estas redes neurais nebulosas, como são comumente chamadas, foram aplicadas em diversos trabalhos para o controle das plantas de tratamento de efluentes.

De acordo com Xiao, Huang, Pan, Liu e Song (2017), o uso de uma grande quantidade de sensores online para o controle e automação das operações de plantas de tratamento tornaram a tomada de decisão manual, baseada na expertise do operador, uma tarefa quase impossível. Para contornar esse problema os autores sugeriram uma metodologia de monitoramento de falhas baseada em redes neurais e análise de séries temporais.

Uma aplicação de redes neurais nebulosas, encontrada em Razvarz e Jafari (2017), foi na resolução do problema causado pela poluição da água por tintas sintéticas, que requerem um complicado sistema fotoquímico (UV/Ag-TiO₂) para serem eliminadas. Os autores comparam redes neurais e uma variante de algoritmos evolutivos (algoritmo de competição imperialista) para modelar o sistema de tratamento visando a predição da eliminação do corante *Acid Yellow 23* (C.I. AY23), ambas as ferramentas obtiveram sucesso, no entanto as redes neurais foram mais precisas. Mais aplicações de redes neurais e redes neurais nebulosa são encontradas no Quadro 1.

QUADRO 1 – APLICAÇÕES DE REDES NEURAIS NO TRATAMENTO DE EFLUENTES

Artigo	Metodologia	Contribuição
Zhou & Qiao (2019)	Algoritmo evolucionário multiobjetivo e redes neurais nebulosas.	Otimização, auxílio na tomada de decisão e controle das concentrações de oxigênio dissolvido e nitrato.

Belchior, Araújo, Souza & Landeck (2018)	Redes neurais nebulosas.	Controle do oxigênio dissolvido em um processo de lodo ativado sujeito a falhas sensoriais.
De Canete, Del Saz-Orozco, Baratti, Mulas, Ruano & Garcia-Cerezo (2016)	Redes neurais.	Predição online das concentrações de: oxigênio dissolvido, nitrogênio total e sólidos suspensos; do efluente em uma planta de lodo ativado, partindo de variáveis mais fáceis de serem medidas como concentração de oxigênio e nitrogênio nos tanques, fluxos de entrada e alcalinidade.
Kusiak & Wei (2014)	Redes neurais nebulosas.	Modelo para a predição da produção de metano no processo de tratamento de efluentes.

Fonte: Elaborado pelos autores (2019).

ALGORITMOS EVOLUTIVOS

Lodo ativado é uma das técnicas mais utilizadas no tratamento de resíduos, sendo o lodo em excesso, cuja disposição final é custosa (metade do valor do tratamento), o principal subproduto do processo (Saadatmandi & Fayyaz, 2018). Logo, é comum que os principais aspectos para melhoria do processo sejam: (1) Regular os valores de variáveis como a concentração de oxigênio dissolvido, de sólidos suspensos e de amônia para atingir maior eficiência operacional; (2) minimizar os custos relativos a eletricidade, produtos químicos, tratamento de lodo em excesso, etc.; (3) melhorar a qualidade do efluente tratado (Lin & Luo, 2015).

Em problemas mono-objetivo - maximizar ou minimizar um conjunto de variáveis - otimizar consiste em encontrar a melhor solução possível, ou algo que se aproxime desta, que solucione o problema levando em conta seu conjunto de restrições.

No entanto, quando há a necessidade de potencializar simultaneamente dois ou mais objetivos, que frequentemente são conflitantes entre si, a otimalidade equivale à definida por Pareto (1964), na qual uma solução é ótima se não existir outra solução factível capaz de diminuir um critério sem causar um aumento simultâneo em ao menos outro fator. Consequentemente, a solução destes problemas não produz uma única resposta, mas um conjunto delas – chamado conjunto ótimo de Pareto - onde os resultados se distinguem por atenderem proporções diferentes de cada objetivo. As soluções contidas neste conjunto são chamadas de não dominadas e atendem aos seguintes critérios: i) não são piores que nenhuma outra solução conjunta em relação a todos os objetivos; ii) são melhores que as outras soluções em pelo menos um objetivo. O gráfico obtido a partir das soluções não dominadas é chamado de fronteira de Pareto (Coello & Zacetenco, 2006).

Algoritmos evolutivos são uma boa alternativa para resolver problemas de otimização multiobjetivo, pois conseguem lidar com um conjunto de possíveis soluções de forma simultânea, permitindo que várias soluções do conjunto ótimo de Pareto sejam encontradas executando o código computacional uma única vez (Abbass & Sarker, 2002).

ALGORITMOS GENÉTICOS

Visam reproduzir o mecanismo de seleção natural onde o indivíduo mais adaptado da população sobrevive. Nos algoritmos genéticos, ao invés de indivíduos temos soluções distintas para o problema em questão e considera-se um conjunto de soluções no lugar da população. Os mecanismos empregados na seleção das melhores respostas para o problema assemelham-se aos

do processo biológico: duas soluções selecionadas da população, de acordo com um critério específico, geram uma nova solução através do intercâmbio de suas características (processo chamado de crossover), durante a geração dos indivíduos da nova população alguns atributos das soluções são alterados propositalmente (processo chamado de mutação) ou clonados (processo chamado de elitismo). O processo de geração de novas populações se repete por um número pré-determinado de vezes ou até que não ocorram mais melhorias nas soluções.

O Algoritmo Genético de Classificação por Não Dominância (NSGA), proposto por Srinivas e Deb (1994), é uma variação do algoritmo genético para a resolução de problemas multiobjetivo. Nesta abordagem os indivíduos são classificados, com base na não dominância, em diferentes categorias antes que a seleção seja efetuada. Todos os indivíduos não dominados devem permanecer na mesma categoria e o processo continua até que todos os indivíduos sejam classificados. Devido a baixa eficiência do NSGA, Deb, Pratap, Agarwal e Meyarivan (2002) propuseram um novo algoritmo, o Algoritmo Genético de Classificação por Não Dominância II (NSGA-II), que além de levar em conta a dominância das soluções também considera a distância de agrupamento – densidade de soluções na vizinhança de uma solução particular – como critério de seleção.

Um exemplo de aplicação desta abordagem na otimização de plantas de tratamento de efluentes é encontrado no trabalho de Qiao & Zhang (2018), no qual os autores elaboraram um sistema de controle dinâmico multiobjetivo para o processo de tratamento de efluentes por meio da seguinte metodologia: (1) construção do modelo de otimização multiobjetivo utilizando redes neurais para estabelecer as relações subjacentes entre os set-points dos controladores e as performances desejadas; (2) otimização dinâmica dos valores de set-point do nitrato e do oxigênio dissolvido empregando algoritmo genético de classificação por não dominância II (NSGA-II); (3) teste da estratégia proposta no modelo *Benchmark Simulation Model 1* (BSM1), onde se verificou uma redução de consumo de energia.

Huang, Ma, Wan & Chen (2015) desenvolveram um software online baseado em algoritmos genéticos e redes neurais nebulosas para o sensoriamento dos compostos presentes nos efluentes a serem tratados. O método proposto foi capaz de fornecer uma previsão acurada da demanda química de oxigênio, NO_3^- e PO_4^{3-} em processos anaeróbicos e aeróbicos.

EVOLUÇÃO DIFERENCIAL

Estes algoritmos partem de uma população gerada aleatoriamente onde cada indivíduo é um vetor cujos elementos variam dentro de um intervalo determinado pelo valor mínimo e máximo que cada variável pode assumir. Na geração de novas soluções, a evolução diferencial usa diferenças entre os vetores como mecanismo de mutação, combinação linear entre os indivíduos selecionados como processo de crossover, além da possibilidade de elitismo (Storn & Price, 1997).

Evolução diferencial foi aplicada por Qiao, Hou, Zhang e Han (2018) para a otimização multiobjetivo do valor de set-point da concentração de oxigênio dissolvido em tanques de tratamento. Os autores também propuseram um sistema de controle adaptativo com rede neural nebulosa para encontrar do valor de set-point da concentração de nitrato em tanques de tratamento anóxicos. Ambas acarretaram em efluentes com melhor qualidade e na redução do custo operacional. Uma abordagem semelhante é encontrada em Qiao, Hou e Han (2019).

SISTEMA IMUNE ARTIFICIAL

Tratam-se de algoritmos inspirados no sistema imunológico onde, em linhas gerais, um antígeno (problema de otimização) é equiparado com um anticorpo (solução) utilizando uma métrica de distância para obter o grau de afinidade (função objetivo) e os anticorpos com maior afinidade são

reproduzidos por clonagem. Detalhes mais aprofundados podem ser encontrados em Coello e Cortés (2005).

Sertkaya e Yurtay (2018) aplicaram sistemas imunes artificiais no banco de dados de tratamento de esgoto da Universidade da Califórnia em Irvine (UCI), conseguindo estimar com sucesso, parâmetros importantes na caracterização de efluentes como pH, demanda bioquímica de oxigênio, demanda química de oxigênio e sólidos suspensos.

ENXAME DE PARTÍCULAS

Algoritmo que imita a maneira com que animais como pássaros e peixes se comportam em relação à procura de alimentos, ou seja, na forma de enxame, onde uma multidão de indivíduos movimentam-se coordenadamente sem que haja nenhum controle central. Um enxame consiste de N partículas que se movimentam no espaço de decisão com direções e velocidades específicas, cada partícula é uma candidata à solução. A direção do movimento de cada partícula se dá no sentido da melhor solução e é redefinida a cada passo levando em conta a última melhor solução por ela visitada e a melhor solução visitada pelo enxame. Cada partícula é composta por três vetores: uma para guardar as posições da partícula no espaço de busca, outro para guardar a posição da melhor solução encontrada até o momento e por fim, um vetor que contém a direção do movimento (Kennedy & Eberhart, 1995).

Han, Zhang, Liu e Qiao (2018) implementaram uma estratégia que melhorou a eficiência operacional, atendeu os níveis de qualidade do efluente e reduziu os gastos energéticos, por meio de um método de controle multiobjetivo composto das seguintes etapas: (1) modelagem da dinâmica entre a qualidade do efluente e o consumo de energia utilizando função do kernel adaptativa; (2) aplicação do algoritmo enxame de partículas para minimizar os objetivos estabelecidos; (2) implementação de um sistema de controle adaptativo com rede neural nebulosa para manter os set-points nos valores adequados.

APRENDIZAGEM REFORÇADA

Consiste na aplicação de métodos para a resolução de problemas onde é necessário extrair informações de um ambiente dinâmico por meio de tentativa e erro. Existem duas estratégias de solução: (1) procurar por comportamentos com o objetivo de encontrar um que tenha um bom desempenho no ambiente em questão; (2) utilizar técnicas estatísticas e programação dinâmica para estimar o desempenho determinadas ações (Kaelbling, Littman & Moore 1996).

Hernández-Del-Olmo, Gaudioso, Dormido e Duro (2018) aplicaram aprendizagem reforçada no controle adaptativo dos níveis de amônia e oxigênio das plantas de tratamento de efluentes, melhorando a eficiência energética e ambiental, além de otimizar os custos operacionais.

APRENDIZAGEM DE MÁQUINA

As técnicas de aprendizagem de máquina podem ser divididas em aprendizagem supervisionada e em aprendizagem não supervisionada, dependendo do tipo de resultado que se deseja obter. A abordagem supervisionada é aplicada nos casos em que se deseja encontrar meios de prever um evento baseando-se em dados pré-existentes e já rotulados possibilitando, por exemplo, prever quando uma máquina irá falhar novamente baseando-se em falhas passadas. Já a abordagem não supervisionada é empregada quando se deseja descrever os dados sem considerar um rótulo pré-existente, como exemplos de aplicações estão o agrupamento de objetos similares e o reconhecimento de padrões (Diez-Olivan, Del Ser, Galar & Sierra 2019).

As técnicas de agrupamento – também conhecidas como *análise de clusters* – são ferramentas da aprendizagem não supervisionada que visam formar grupos com base na similaridade dos pontos. Dentre os tipos de agrupamento estão: (1) hierárquico, onde os dados são alocados em grupos que podem ou não estar contidos em grupos maiores (ex: classificação filogenética); (2) o em torno de centroides, que agrupa os dados em torno de k pontos (centroides) escolhidos aleatoriamente ou utilizando uma heurística (Provost & Fawcett, 2016).

Chow, Liu, Li, Swain, Reid e Saint (2018), com o objetivo de prever situações adversas que pudessem afetar negativamente o sistema de tratamento, utilizaram a análise de clusters para desenvolver um sistema de alerta em tempo real que detecta e classifica anomalias com base nas concentrações de amônia, fosfato, nitrito, nitrato e sólidos suspensos, obtidas de análises espectroscópicas online do efluente.

Máquina de vetor de suporte é uma técnica de aprendizagem supervisionada que classifica os dados com base em uma função objetivo, onde o ajustamento é feito traçando-se duas linhas que seccionam os dados, denominadas vetores suporte. Esta técnica foi aplicada por Xiao, Bai, Li, Liu, Liu e Huang (2019), juntamente com regressão multivariada para obter valores preditivos e indicar com credibilidade variáveis como oxigênio dissolvido, nitrogênio total e sólidos suspensos.

CONSIDERAÇÕES FINAIS

Pode-se notar que a inteligência artificial foi predominantemente empregada com o objetivo de resolver problemas relativos ao controle do processo biológico das plantas de tratamento de efluentes. Possivelmente isto se decorreu do fato de que, segundo Yetilmezsoy, Ozgun, Dereli, Ersahin e Ozturk (2015), o desempenho dos sistemas de tratamento biológico depende de diversos fatores que decorrem das diferentes características do efluente a ser tratado (pH, composição química, sólidos dissolvidos, entre outros.) e condições operacionais (temperatura, tempo de retenção, entre outros). Como consequência disto, detalhar os dinamismos biológicos, os mecanismos de reação e as variáveis do processo em um modelo matemático para o controle e aperfeiçoamento da operação torna-se uma tarefa árdua e dispendiosa. Desta forma, modelos baseados em inteligência artificial são uma maneira rápida e prática de otimizar, controlar e monitorar o processo.

Também verificou-se que a técnica mais utilizada foram as redes neurais nebulosas, o motivo para tal pode ser explicado pela já citada dificuldade de desenvolver um modelo matemático para os processos biológicos de tratamento de efluentes e pela característica das redes neurais serem capazes de resolver problemas partindo apenas de um conjunto de dados.

REFERÊNCIAS

- Abbass, H. A., & Sarker, R. (2002). The Pareto differential evolution algorithm. *International Journal on Artificial Intelligence Tools*, 11(04), 531-552.
- Belchior, C. A. C., Araújo, R. A. M., Souza, F. A. A., & Landeck, J. A. C. (2018). Sensor-fault tolerance in a wastewater treatment plant by means of ANFIS-based soft sensor and control reconfiguration. *Neural Computing and Applications*, 30(10), 3265-3276.
- Buckley, J. J. & Hayashi, Y. (1994). Fuzzy neural networks: A survey. *Fuzzy Sets and Systems*, 66, pp. 1-13.
- Cheng, H., Wu, J., Liu, Y., & Huang, D. (2019). A novel fault identification and root-causality analysis of incipient faults with applications to wastewater treatment processes. *Chemometrics and Intelligent Laboratory Systems*, 188, 24-36.

- Chow, C. W., Liu, J., Li, J., Swain, N., Reid, K., & Saint, C. P. (2018). Development of smart data analytics tools to support wastewater treatment plant operation. *Chemometrics and Intelligent Laboratory Systems*, 177, 140-150.
- Coello, C., De Computación, S., & Zacatenco, C. (2006). Twenty years of evolutionary multi-objective optimization: A historical view of the field. *IEEE computational intelligence magazine*, 1(1), 28-36.
- Coello, C. A. C., & Cortés, N. C. (2005). Solving multiobjective optimization problems using an artificial immune system. *Genetic Programming and Evolvable Machines*, 6(2), 163-190.
- De Canete, J. F., Del Saz-Orozco, P., Baratti, R., Mulas, M., Ruano, A., & Garcia-Cerezo, A. (2016). Soft-sensing estimation of plant effluent concentrations in a biological wastewater treatment plant using an optimal neural network. *Expert Systems with Applications*, 63, 8-19.
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. A. M. T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE transactions on evolutionary computation*, 6(2), 182-197.
- Diez-Olivan, A., Del Ser, J., Galar, D., & Sierra, B. (2019). Data fusion and machine learning for industrial prognosis: Trends and perspectives towards industry 4.0. *Information Fusion*, 50, 92-111.
- Han, H. G., Zhang, L., Liu, H. X., & Qiao, J. F. (2018). Multiobjective design of fuzzy neural network controller for wastewater treatment process. *Applied Soft Computing*, 67, 467-478.
- Hernández-del-Olmo, F., Gaudioso, E., Dormido, R., & Duro, N. (2018). Tackling the start-up of a reinforcement learning agent for the control of wastewater treatment plants. *Knowledge-Based Systems*, 144, 9-15.
- Huang, M., Ma, Y., Wan, J., & Chen, X. (2015). A sensor-software based on a genetic algorithm-based neural fuzzy system for modeling and simulating a wastewater treatment process. *Applied Soft Computing*, 27, 1-10.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- Kennedy, J., & Eberhart, R. C. (1995). Particle swarm optimization. In *IEEE International Conference on Neural Networks*, Perth, Australia, pp. 1942-1948.
- Kusiak, A., & Wei, X. (2014). Prediction of methane production in wastewater treatment facility: a data-mining approach. *Annals of Operations Research*, 216(1), 71-81.
- Lin, M. J., & Luo, F. (2015). An adaptive control method for the dissolved oxygen concentration in wastewater treatment plants. *Neural Computing and Applications*, 26(8), 2027-2037.
- Milidiu, R. L (1995). *Fundamentos de redes neurais*. Curitiba: Sociedade Brasileira de Matemática Aplicada e Computacional.
- Pareto, V. (1964). *Cours d'économie politique (Vol. 1)*. Librairie Droz.
- Provost, F. & Fawcett, T (2016). *Data Science para negócios*. Rio de Janeiro: Alta Books.
- Qiao, J. F., Hou, Y., & Han, H. G. (2019). Optimal control for wastewater treatment process based on an adaptive multi-objective differential evolution algorithm. *Neural Computing and Applications*, 31(7), 2537-2550.
- Qiao, J. F., Hou, Y., Zhang, L., & Han, H. G. (2018). Adaptive fuzzy neural network control of wastewater treatment process with multiobjective operation. *Neurocomputing*, 275, 383-393.
- Qiao, J., & Zhang, W. (2018). Dynamic multi-objective optimization control for wastewater treatment process. *Neural Computing and Applications*, 29(11), 1261-1271.

- Razvarz, S., & Jafari, R. (2017). ICA and ANN Modeling for Photocatalytic Removal of Pollution in Wastewater. *Mathematical and Computational Applications*, 22(3), 38.
- Saadatmandi, A., & Fayyaz, S. (2018). Chebyshev finite difference method for solving a mathematical model arising in wastewater treatment plants. *Computational Methods for Differential Equations*, 6(4), 448-455.
- Sertkaya, C., & Yurtay, N. (2018). Artificial immune system based wastewater parameter estimation. *Turkish Journal of Electrical Engineering & Computer Sciences*, 26(6), 3356-3366.
- Srinivas, N., & Deb, K. (1994). Multiobjective optimization using nondominated sorting in genetic algorithms. *Evolutionary computation*, 2(3), 221-248.
- Storn, R., & Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4), 341-359.
- Xiao, H., Bai, B., Li, X., Liu, J., Liu, Y., & Huang, D. (2019). Interval multiple-output soft sensors development with capacity control for wastewater treatment applications: A comparative study. *Chemometrics and Intelligent Laboratory Systems*, 184, 82-93.
- Xiao, H., Huang, D., Pan, Y., Liu, Y., & Song, K. (2017). Fault diagnosis and prognosis of wastewater processes with incomplete data by the auto-associative neural networks and ARMA model. *Chemometrics and Intelligent Laboratory Systems*, 161, 96-107.
- Yetilmezsoy, K., Ozgun, H., Dereli, R. K., Ersahin, M. E., & Ozturk, I. (2015). Adaptive neuro-fuzzy inference-based modeling of a full-scale expanded granular sludge bed reactor treating corn processing wastewater. *Journal of Intelligent & Fuzzy Systems*, 28(4), 1601-1616.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3), 338-353.
- Zadorojniy, A., Wasserkrug, S., Zeltyn, S., & Lipets, V. (2019). Unleashing Analytics to Reduce Costs and Improve Quality in Wastewater Treatment. *Interfaces*, 49(4), 262-268.
- Zhou, H., & Qiao, J. (2019). Multiobjective optimal control for wastewater treatment process using adaptive MOEA/D. *Applied Intelligence*, 49(3), 1098-1126.