

## **XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS**

### **O USO DE REDES NEURAIS EM RECURSOS HIDRÍCOS**

*Sabrina Bittencourt Medeiros Drummond<sup>1</sup>; Maria Cristina Borba Braga<sup>2</sup>; Eloy Kaviski<sup>3</sup>; Sérgio Michelotto Braga<sup>4</sup>*

**Abstract:** Over the past two decades, artificial neural networks have become a valuable tool for addressing complex challenges in water resources management. They are applicable in situations where traditional methods struggle to grasp the intricacies of the issues involved. This study highlights various applications of these tools, presenting their capability to capture nonlinear relationships in hydrology. It includes examples ranging from basic flow predictions to the dynamics of sediment in reservoirs. A search of the Scopus database exhibited more than 56,000 publications on artificial neural networks over the past two decades, with over 50,000 of these published in just the last ten years. This significant volume of scientific output is due to the unique advantages of artificial neural networks, including their adaptability to various scenarios and their capability to process information in real-time. Additionally, this study highlights the application of these tools in recent real-world situations, such as managing extreme events and monitoring water quality. These results attest to the effectiveness of these techniques in the field of water resources management.

**Keywords** – artificial intelligence, non-linear modelling, computational modeling.

**Resumo:** Nas últimas duas décadas, as redes neurais artificiais surgiram como ferramenta promissora para lidar com desafios multifacetados como a gestão de recursos hídricos, especialmente em situações em que os métodos convencionais se mostram insuficientes para descrever com sucesso a complexidade dos problemas. Este estudo apresenta exemplos do uso diversificado dessas ferramentas e a sua capacidade para capturar relações não lineares em hidrologia, exemplificando desde previsões mais simples de vazão, até a dinâmica de sedimentos em reservatórios. Uma pesquisa realizada na base de dados Scopus apontou a existência de mais de cinquenta e seis mil publicações sobre o assunto nas últimas duas décadas, sendo que mais de cinquenta mil apenas nos últimos dez anos. O volume da produção científica associado ao tema está associado às vantagens peculiares das redes neurais artificiais, como a adaptabilidade a diferentes cenários e a habilidade de processar informação em tempo real. Este estudo também aponta o uso da ferramenta em casos reais recentes, incluindo o gerenciamento de eventos extremos e o monitoramento da qualidade da água, ilustrando a capacidade dessas técnicas em relação à gestão de recursos hídricos.

**Palavras-Chave** – inteligência artificial, modelagem não linear, modelagem computacional.

1) Universidade Federal do Paraná, PR, Brasil, (41) 99623-0101, drummond.sabrina@gmail.com

2) Universidade Federal do Paraná, PR, Brasil, crisbraga@ufpr.br

3) Universidade Federal do Paraná, PR, Brasil, eloy.dhs@ufpr.br

4) Universidade Federal do Paraná, PR, Brasil, sergio.dhs.ufpr@gmail.com

## INTRODUÇÃO

As redes neurais artificiais (RNAs) têm sido aplicadas para a solução de problemas de difícil previsão, como os relacionados aos recursos hídricos, em que as conexões entre as variáveis não são completamente conhecidas. Entretanto, para que modelos baseados em RNAs forneçam previsões precisas, é crucial atender a certos requisitos. De acordo com Baker e colaboradores (2018), isso inclui a disponibilidade de grande volume de dados ou intensa interação entre a RNA e o ambiente, escolha do algoritmo correto e definição das entradas e saídas de interesse.

Uma rede neural consiste tipicamente em unidades de processamento ou neurônios, simples e conectadas, que produzem uma sequência de ativações. Os neurônios de entrada são ativados por um estímulo e, por sua vez, ativam outros neurônios por meio de conexões ponderadas, ditas peso sináptico (Schmidhuber, 2015). A função aditiva é necessária para somar os sinais de entrada, ponderados pelas sinapses dos neurônios. As funções de ativação são, por associação, os sinais *eletroquímicos* recebidos e transmitidos pelo neurônio. Assim, a função de ativação define a resposta de saída de um neurônio ou a forma como um estímulo é respondido. Os formatos das funções que podem ser atribuídas podem ser linear ou sigmóide (Haykin, 2001; Munakata, 2008).

Os tipos mais comuns de configuração de rede são aqueles alimentados adiante, ou *feedforward*, com uma ou múltiplas camadas. Neste caso, os neurônios são organizados em uma ou mais camadas com os dados organizados unidirecionalmente entre eles. De forma geral, as redes alimentadas adiante são estáticas, isto é, produzem apenas um conjunto de valores de saída. Por sua vez, as redes recorrentes, ou de *feedback*, constituem sistemas dinâmicos. Neste caso, quando um novo padrão de entrada é apresentado, as saídas do neurônio são computadas e, devido à retroalimentação, as entradas para cada neurônio são modificadas (Jain, 1996).

Os primeiros a propor um modelo matemático para a construção de redes neurais foram Warren McCullough e Walter Pitts, em 1943. No entanto, foi apenas com o aprimoramento da computação eletrônica e o desenvolvimento matemático dos trabalhos de Hopfield (1982) e Rumelhart et al. (1986) que surgiu a possibilidade de buscar aplicação desta ferramenta computacional além do campo teórico.

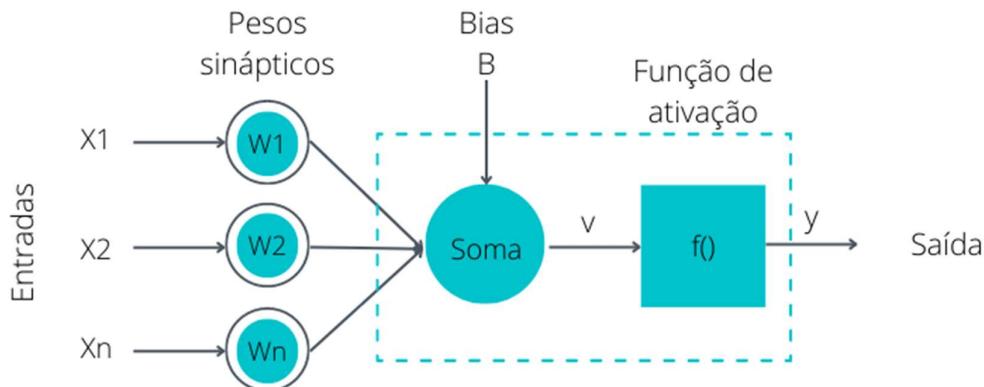
Semelhante ao sistema nervoso central humano, o princípio das redes neurais proposto por McCullough e Pitts seria um neurônio artificial, que imita a plasticidade do pensamento humano, principalmente o processo de aprendizado por experiência. De acordo com Haykin (2001) a rede neural seria o equivalente a uma ferramenta concebida para modelar a maneira como o cérebro realiza uma tarefa de interesse. Os neurônios artificiais seriam unidades de processamento que recebem um estímulo, ou dados de entrada e produzem uma resposta, ou dados de saída. Quanto maior o número de neurônios ligados para formar uma rede, melhor será o resultado potencial para decisões complexas. Em 1958, Rosenblat concebeu o *perceptron*, a rede neural mais antiga com apenas um neurônio conforme apresentado na Figura 1.

A arquitetura da rede neural é o padrão de conexão entre os neurônios (Munakata, 2008). Diferentes arquiteturas de redes neurais requerem técnicas, paradigmas e algoritmos de aprendizado apropriados. A arquitetura do sistema é elaborada de acordo com as características do resultado que se pretende obter sendo possível diversos arranjos de redes neurais.

Haykin (2001) propôs um conceito de aprendizagem de redes neurais como o processo pelo qual parâmetros livres de uma rede neural são adaptados por meio de um processo de estímulo do ambiente no qual a rede está inserida, e que o tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre. Um conjunto preestabelecido de regras para a solução de

um problema de aprendizagem é denominado algoritmo de aprendizagem. Enquanto a forma do modelo do ambiente na qual a rede neural opera refere-se ao paradigma de aprendizagem, isto é, supervisionado, não supervisionado ou híbrido.

Figura 1 – Representação esquemática de um neurônio



Nota:  $x_n$  = dados de entrada;  $w_n$  = pesos sinápticos;  $B$  = bias;  $f()$  = função de ativação;  $y$  = dados de saída

De acordo com Jain (1996), na modalidade supervisionada, ou aprendizado com um “professor”, a rede recebe uma resposta ou saída correta para cada padrão de entrada. Subsequentemente, pesos sinápticos são determinados para que a rede produza respostas o mais próximas possível das respostas corretas conhecidas e recebidas pela rede. A modalidade por reforço é uma variante do aprendizado supervisionado, na qual a rede recebe apenas uma crítica sobre a acurácia das saídas, não as respostas corretas em si. Por outro lado, o aprendizado não supervisionado ou “sem professor” não requer uma resposta correta associada a cada entrada no conjunto de dados de treinamento. Esta modalidade explora a estrutura subjacente dos dados ou as correlações entre os padrões dos dados e os organiza em categorias a partir das correlações. Por sua vez, o aprendizado híbrido combina o supervisionado e o não supervisionado. Parte dos pesos sinápticos são normalmente determinados por meio de aprendizado supervisionado, enquanto os demais são obtidos por meio não supervisionado. A quantidade de pesos é determinada em função do número de neurônios nas camadas de entrada e saída e do número de neurônios nas camadas intermediárias. O número de neurônios nas camadas de entrada e saída dependem do problema a ser resolvido.

Os processos utilizados no processo de aprendizagem são derivados de técnicas de otimização, que podem conter critérios objetivos para estabelecer o número de camadas intermediárias e o número de neurônios nestas camadas. Portanto, é um problema em aberto. Em geral, são utilizadas técnicas de computação evolutiva e metaheurísticas, isto é, algoritmo genético, colônia de formigas, busca Tabu, reconhecimento simulado, entre outros.

## O USO DE REDES NEURAIS APLICADAS AOS RECURSOS HÍDRICOS

O interesse científico para a aplicação de redes neurais aos recursos hídricos motivou o início de trabalhos de previsão do volume de lodo de esgoto (Capodaglio et al., 1991), da qualidade da água (Maier e Dandy, 1993), da vazão (Zhu e Fujita, 1993, Lachtermacher e Fuller, 1993), do transporte de sedimentos (Trent et al., 1993) e, também, do escoamento em eventos de precipitação (Hsu et al., 1995; Shamseldin, 1997; Tokar e Johnson, 1999); além da estimativa de hidrograma unitário (Hjelmfelt et al., 1993). Tais aplicações ainda são praticadas e se expandem em outras aplicações com estudos relacionados à hidrologia e à qualidade da água.

Nas últimas duas décadas, têm apresentado progresso para a previsão e modelagem não linear, isto é, com capacidade para representar a não linearidade da aplicação hidrológica (Maier et al., 2010; Yaseen et al., 2015). Na base de dados Scopus, por exemplo, para a busca "rede neural artificial + recursos hídricos", o número de artigos listados nos últimos 20 anos ultrapassa 56 mil, com mais de 50 mil apenas na última década. Na Tabela 1, são apresentados alguns exemplos de aplicações de RNAs em recursos hídricos nos últimos dez anos.

Tabela 1 – Exemplos de RNAs no campo de recursos hídricos nos últimos dez anos

| Autor(es)       | Aplicação  | Método   | Comentários   |
|-----------------|--|--|---|
| Hsu (2015)      | Controle de cheias em tempo real em reservatórios durante tufões | ANFIS (Adaptive Neuro-Fuzzy Inference System) e RTRLNN (Real-Time Recurrent Learning Neural Network) | Utiliza variáveis hidrológicas como dados de entrada  |
| Gazendam (2016) | Avaliação de habitats aquáticos para projetos de restauração     | RNA  | Modelo com 112 locais e 31 variáveis de entrada   |
| Huang (2017)    | Sedimentação em reservatórios                                    | ANFIS e RTRLNN   | ANFIS simulou hidrogramas com eficácia e RTRLNN mostrou bom desempenho em regimes de fluxo dominados por carga de fundo |

Continuação Tabela 1

|              |   |   |  |
|--------------|---|---|--|
| Zhang (2018) | Simulação e previsão de níveis em estruturas de transbordo de esgoto combinado                  | MLP (Multilayer Perceptron), WNN (Wavelet Neural Network), LSTM (Long Short-Term Memory) e GRU (Gated Recurrent Unit) | Uso de inteligência artificial integrada à Internet das Coisas   |
| Zhang (2019) | Previsão de desempenho em estações de tratamento de água potável                                | HANN (Hybrid Artificial Neural Network) e AG (Algoritmo Genético)   | Combinação de parâmetros de qualidade da água e operacionais   |
| Li (2020)    | Ocorrência de hidrocarbonetos policíclicos aromáticos em material particulado suspenso aquático | SOM (Self-Organizing Map) e PMF (Positive Matrix Factorization)   | Dados de monitoramento de 20 anos  |
| Fang (2021)  | Desempenho de biofiltros em águas pluviais  | RNA + 2 outras técnicas de aprendizado de máquina   | Redução de riscos à saúde associados a metais pesados em águas pluviais com a utilização de biofiltros   |
| Lai (2022)   | Impacto das mudanças climáticas em reservatórios  | RNA e SVR (Support Vector Regression)   | Uso de precipitação, temperatura e radiação solar como parâmetros de entrada                             |
| Zhu (2022)   | Gestão de reservatórios em cascata  | Três tipos de IA: R2, RMSE e STD  | Simulações de cenários hidrológicos  |
| Li (2023)    | Identificação de fontes potenciais de substâncias perfluoroalquiladas (PFAS) em corpos hídricos | PMF e SOM   | 812 amostras de água superficial de seis estações de monitoramento                                       |
| Song (2023)  | Contaminação de águas subterrâneas  | MC3D-CNN (3D Convolutional Neural Network)  | Acurácia >90% na classificação de poços de extração e >80% na previsão de locais ótimos para novos poços |

Continuação Tabela 1

|                |   |                               |  |
|----------------|---|-------------------------------|--|
| Hou (2024)     | Análise de tendências espaço-temporais de coliformes fecais       | SARIMA (Seasonal ARIMA) e RNA | Uso de modelo baseado em processos para gerar dados de treinamento |
| Busari (2024)  | Previsão de clorofila-a como indicador de florações algas nocivas | LSTM                          | Integração com sensores em tempo real e Internet das Coisas (IoT)  |
| Koundal (2025) | Remoção de arsênio em água potável                                | RNA                           | Otimização de membranas de filtro passivo                          |
| Das (2025)     | Avaliação da qualidade da água                                    | RNA                           | Aplicação combinada de CILOS, SIG, RNA e técnicas de decisão       |

O crescente número de aplicações de RNAs no campo dos recursos hídricos pode ser atribuído à maior capacidade de resolução de problemas em comparação com métodos lineares, como aqueles baseados em regressão múltipla, por exemplo. As RNAs são capazes de modelar funções mais complexas com maior precisão (Yang, 2023). Além disso, uma RNA pode revelar relações e padrões ocultos nos dados que, mesmo em bacias hidrográficas extensivamente estudadas, os modelos baseados em processos físicos podem não considerar todos os fatores condicionantes subjacentes (Li, 2022; Song, 2023). Outra vantagem é a rapidez de resposta em que, muitas vezes, após a implementação do modelo decisões podem ser tomadas com base em dados em tempo real (Zhu, 2022).

## CONCLUSÃO

As aplicações das RNAs, conforme apresentado, destacam o seu papel na solução de problemas complexos em recursos hídricos, superando, muitas vezes, limitações de métodos lineares e modelos físicos tradicionais. Seja na previsão de cheias ou na otimização da operação de estações de tratamento de água estas ferramentas têm se mostrado efetivas para extrair relações não lineares de grandes volumes de dados em associação à rapidez de resposta em tempo real. A adaptação a diferentes soluções de problemas e cenários decorre principalmente da diversidade de arquiteturas, algoritmos e paradigmas de aprendizado.

Como tendência, observa-se o uso integrado de RNAs com tecnologias emergentes como IoT (*Internet of Things*) outros tipos de inteligência artificial, por exemplo, Algoritmos Genéticos, entre outras e, ainda, o uso acoplado a modelos determinísticos tradicionais. Seu uso aponta ainda aplicações promissoras na otimização de decisões em cenários de mudanças climáticas e escassez hídrica.

Entretanto, faz-se necessário reconhecer as limitações e obstáculos para o uso das RNAs, a citar a necessidade de dados robustos para treinamento e a denominada "caixa preta" dos algoritmos mais complexos, que desafiam a interpretação dos resultados.

Cabe salientar que o uso potencial das RNAs demanda investimento não apenas em relação à técnica propriamente dita, mas, em especial na formação de profissionais qualificados para integrar o conhecimento clássico já adquirido pela hidrologia com a abordagem inovadora das inteligências artificiais visando à segurança hídrica e à sustentabilidade do uso da água.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## REFERÊNCIAS

BUSARI, I.; SAHOO, D.; JANA, R.B. (2024). “Prediction of chlorophyll-a as an indicator of harmful algal blooms using deep learning with Bayesian approximation for uncertainty assessment”. *Journal of Hydrology*, v. 630, 130627.

CAPODAGLIO, A.; JONES, H.V.; NOVOTNY, V.; FENG, X. (1991). “Sludge bulking analysis and forecasting: application of system identification and artificial neural computing technologies”. *Water Research*, v. 25, n. 10, p. 1217-1224.

DAS, A. (2025). “Water pollution and water quality assessment and application of criterion impact loss (CILOS), geographical information system (GIS), artificial neural network (ANN) and decision-learning technique in river water quality management: An experiment on the Mahanadi catchment, Odisha, India”. *Desalination and Water Treatment*, v. 361, 100969.

FANG, H.; JAMALI, B.; DELETIC, A.; ZHANG, K. (2021). “Machine learning approaches for predicting the performance of stormwater biofilters in heavy metal removal and risk mitigation”. *Water Research*, v. 200, 117273.

GAZENDAM, E.; GHARABAGHI, B.; ACKERMAN, J.D.; WHITELEY, H. (2016). “Integrative neural networks models for stream assessment in restoration projects”. *Journal of Hydrology*, v. 536, p. 339-350.

HAYKIN, S. (2001). *Redes neurais: princípios e prática*. Bookman Editora, 898 p.

HJELMFELT, T.A. JR.; WANG, M. (1993). “Artificial neural networks as unit hydrograph applications”. *Engineering Hydrology*, New York: Hydraulics Division of ASCE, p. 754-759.

HOPFIELD, J.J. (1982). “Neural networks and physical systems with emergent collective computational abilities”. *Proceedings of the National Academy of Sciences*, v. 79, n. 8, p. 2554-2558.

HOU, X.; QIN, L.; WANG, F.; XU, C.; HANG, Y.; ZHANG, T.; WU, B.; WANG, D.; LI, M. (2024). “Faecal contamination in China: Trends, sources, and driving mechanisms”. *Water Research*, v. 261, 122017.

HSU, K.; GUPTA, V.H.; SOROOSHIAN, S. (1995). "Artificial neural network modeling of the rainfall-runoff process". *Water Resources Research*, v. 31, n. 10, p. 2517-2530.

HSU, N.S.; HUANG, C.L.; WEI, C.C. (2015). "Multi-phase intelligent decision model for reservoir real-time flood control during typhoons". *Journal of Hydrology*, v. 522, p. 11-34.

HUANG, C.L.; HSU, N.S.; WEI, C.C.; YAO, C.H. (2017). "Trade-off analysis of discharge-desiltation-turbidity and ANN analysis on sedimentation of a combined reservoir-reach system under multi-phase and multi-layer conjunctive releasing operation". *Journal of Hydrology*, v. 553, p. 596-623.

JAIN, A.K.; MAO, J.; MOHIUDDIN, K.M. (1996). "Artificial neural networks: A tutorial". *Computer*, v. 29, n. 3, p. 31-44.

KOUNDAL, D.; BAJPAI, S. (2025). "Artificial neural network based modeling and simulation of spiral wound Nano-filtration module and analyzing input responses for removal of Arsenic (V) from potable water". *Journal of the Indian Chemical Society*, v. 102, 101579.

LACHTERMACHER, G.; FULLER, J.D. (1993). "Backpropagation in Hydrological Time Series Forecasting", in *Stochastic and Statistical Methods in Hydrology and Environmental Engineering*. Org. por Hipel, K.W., McLeod, A.I., Panu, U.S., Singh, V.P., Springer, Dordrecht, pp. 303-309.

LAI, V.; HUANG, Y.F.; KOO, C.H.; AHMED, A.N.; EL-SHAFIE, A. (2022). "Conceptual Sim-Heuristic optimization algorithm to evaluate the climate impact on reservoir operations". *Journal of Hydrology*, v. 614, 128530.

LI, R.; HUA, P.; ZHANG, J.; KREBS, P. (2020). "Effect of anthropogenic activities on the occurrence of polycyclic aromatic hydrocarbons in aquatic suspended particulate matter: Evidence from Rhine and Elbe Rivers". *Water Research*, v. 179, 115901.

LI, K.; HUANG, G.; WANG, S.; RAZAVI, S. (2022). "Development of a physics-informed data-driven model for gaining insights into hydrological processes in irrigated watersheds". *Journal of Hydrology*, v. 613, 128323.

LI, H.; ZHU, X.; ZHANG, J.; WANG, Z.; LI, R. (2023). "Characterizing the long-term occurrence and anthropogenic drivers of per- and polyfluoroalkyl substances in surface water of the Rhine River". *Water Research*, v. 245, 120528.

MAIER, H.R.; JAIN, A.; DANDY, G.C.; SUDHEER, K.P. (2010). "Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions". *Environmental Modelling & Software*, v. 25, n. 8, p. 891-909.

MCCULLOCH, W.S.; PITTS, W. (1943). "A logical calculus of the ideas immanent in nervous activity". *The Bulletin of Mathematical Biophysics*, v. 5, n. 4, p. 115-133.

MUNAKATA, T. (2008). *Fundamentals of the New Artificial Intelligence: Neural, Evolutionary, Fuzzy and More*. 2nd ed. London: Springer.

- RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. (1986). "Learning representations by back-propagating errors". *Nature*, v. 323, n. 6088, p. 533-536.
- SCHMIDHUBER, J. (2015). "Deep learning in neural networks: An overview". *Neural Networks*, v. 61, p. 85-117.
- SHAMSELDIN, A. (1997). "Application of a neural network technique to rainfall-runoff modeling". *Journal of Hydrology*, v. 199, p. 272-294.
- SONG, X.; REN, H.; HOU, Z.; LIN, X.; KARANOVIC, M.; TONKIN, M.; FREEDMAN, V.L.; DEMIRKANLI, I.; MACKLEY, R. (2023). "Predicting future well performance for environmental remediation design using deep learning". *Journal of Hydrology*, v. 617, 129110.
- TOKAR, A.S.; JOHNSON, P.A. (1999). "Rainfall-runoff modeling using artificial neural networks". *Journal of Hydrologic Engineering*, v. 4, n. 3, p. 232-239.
- TRENT, R.; MOLINAS, A.; GAGARIN, N. (1993). "An artificial neural network for computing sediment transport", in *Proceedings of the ASCE Hydraulics Conference*, San Francisco, CA., Hydraulic Engineering, p. 1049-1054.
- YANG, B.; XIAO, Z.; MENG, Q.; YUAN, Y.; WANG, W.; WANG, H.; WANG, Y.; FENG, X. (2023). "Deep learning-based prediction of effluent quality of a constructed wetland". *Environmental Science and Ecotechnology*, v. 13, 100207.
- YASEEN, Z.M.; EL-SHAFIE, A.; JAAFAR, O.; AFA, H.A.; SAYL, K.N. (2015). "Artificial intelligence-based models for stream-flow forecasting: 2000–2015". *Journal of Hydrology*, v. 530, p. 829-844.
- ZHANG, D.; LINDHOLM, G.; RATNAWEERA, H. (2018). "Use long short-term memory to enhance Internet of Things for combined sewer overflow monitoring". *Journal of Hydrology*, v. 556, p. 409-418.
- ZHANG, Y.; GAO, X.; SMITH, K.; INIAL, G.; LIU, S.; CONIL, L.B.; PAN, B. (2019). "Integrating water quality and operation into prediction of water production in drinking water treatment plants by genetic algorithm enhanced artificial neural network". *Water Research*, v. 164, 114888.
- ZHU, B.; LIU, J.; LIN, J.; LIU, Y.; ZHANG, D.; REN, Y.; PENG, Q.; YANG, J.; HE, H.; FENG, Q. (2022). "Cascade reservoirs adaptive refined simulation model based on the mechanism-AI coupling modeling paradigm". *Journal of Hydrology*, v. 612, 128229.
- ZHU, M.; FUJITA, M.; HASHIMOTO, N. (1994). "Application of Neural Networks to Runoff Prediction", in *Stochastic and Statistical Methods in Hydrology and Environmental Engineering*. Org. por Hipel, K.W., McLeod, A.I., Panu, U.S., Singh, V.P., Springer, Dordrecht, pp. 205-214.