

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

### **PREVISÃO DE VAZÕES COM REDES NEURAIS ARTIFICIAIS NA BACIA DO ALTO PARAGUAI**

*Thaiana Todeschini<sup>1</sup>; Frederico Carlos Martins de Menezes Filho<sup>2</sup>*

**Abstract:** The increasing demand for water, driven by urban growth and the intensification of agricultural activities, has amplified the challenges related to water resources management, especially in ecologically sensitive regions such as the Pantanal. The Upper Paraguay Basin, which encompasses the Pantanal, one of the largest continuous wetland areas on the planet, stands out for its hydrological importance. Traditional forecasting models, based on water balance, require large volumes of data and specific basin information, which limits their applicability in data-scarce regions. In this context, machine learning-based models have emerged as viable alternatives due to their lower data requirements and good performance in time series forecasting. Among these, Artificial Neural Networks (ANNs) are notable for their ability to capture complex hydrological patterns with high accuracy. Among the ANN architectures, the Multi-Layer Perceptron (MLP) has proven effective in modeling hydrological time series. This study evaluated the predictive performance of the MLP in forecasting monthly average streamflows in the Itiquira River Basin, located in the Upper Paraguay region, in the state of Mato Grosso, Brazil, for forecasting horizons of 3, 6, 9, and 12 months. The results showed satisfactory performance, with an RMSE of 0.013 and NSE of 0.99, for a 12-month forecast horizon. These findings highlight the strong capability of the MLP to model seasonal patterns, reinforcing its potential as a decision-support tool for hydrological management in regions with limited data availability.

**Keywords:** time series, machine learning, Pantanal.

**Resumo:** O aumento da demanda por água, impulsionado pelo crescimento urbano e pela intensificação das atividades agropecuárias, tem ampliado os desafios relacionados à gestão dos recursos hídricos, especialmente em regiões ecologicamente sensíveis como o Pantanal. A Bacia do Alto Paraguai, que compreende o Pantanal, uma das maiores áreas úmidas contínuas do planeta, destaca-se por sua relevância hidrológica. Modelos tradicionais de previsão, baseados em balanço hídrico, requerem grande volume de dados e informações específicas da bacia, o que limita sua aplicabilidade em áreas com escassez de dados. Nesse contexto, modelos baseados em aprendizagem de máquina têm se destacado como alternativas viáveis, por exigirem menor volume de dados e apresentarem bom desempenho na previsão de séries temporais. Entre esses, destacam-se as Redes Neurais Artificiais (RNA), capazes de capturar padrões hidrológicos complexos com elevada acurácia. Dentre as arquiteturas de RNA, a Multi-Layer Perceptron (MLP) tem se mostrado eficaz na modelagem de séries temporais hidrológicas. Este estudo avaliou o desempenho da MLP na previsão de vazões médias mensais na Bacia Hidrográfica do Rio Itiquira, localizada na região do Alto Paraguai, em Mato Grosso, para os horizontes de 3, 6, 9 e 12 meses. Os resultados demonstraram desempenho satisfatório do modelo, com RMSE de 0,013 e NSE de 0,99 para um horizonte de 12 meses. Tais resultados evidenciam a elevada capacidade da MLP em modelar padrões sazonais, reforçando seu potencial como ferramenta de suporte à gestão hidrológica em regiões com escassez de dados.

**Palavras-Chave:** séries temporais, aprendizado de máquina, Pantanal.

1) TPF Engenharia, thaiana.todeschini@tpfe.com.br

2) Universidade Federal de Viçosa, Campus Rio Paranaíba, frederico.menezes@ufv.br

## INTRODUÇÃO

O aumento da demanda hídrica, decorrente da intensificação das atividades antrópicas e da expansão demográfica, tem acentuado a necessidade de estratégias eficientes de previsão e gestão dos recursos hídricos. Uma gestão adequada de recursos hídricos é essencial para garantir a segurança hídrica e abastecimento das demandas de água (Siqueira, 2021). Isso destaca a urgência de aprimorar as estratégias de previsão para mitigar impactos adversos em áreas urbanas e setores essenciais, como agricultura, abastecimento de água e geração de energia elétrica (Shah *et al.*, 2023).

Tradicionalmente, os modelos físicos, baseados no balanço hídrico têm sido amplamente utilizados para simular a interação complexa entre precipitação, escoamento superficial, infiltração e evapotranspiração (Naganna *et al.*, 2023). No entanto, tais modelos podem exigir grande disponibilidade de informações, tais quais plantas altimétricas, mapas pedológicos, além de dados de uso e cobertura do solo, precipitação e vazão, estando sujeitos às limitações quanto à disponibilidade destas informações (Nguyen *et al.*, 2023).

Por outro lado, os modelos de aprendizagem de máquina (Machine Learning) representam uma abordagem probabilística para a previsão hidrológica. Apesar de não considerar a relação entre os processos físicos ocorridos na bacia hidrográfica, tais modelos requerem qualidade dos dados coletados, permitindo gerar séries temporais de vazões longas com características estatísticas semelhantes às séries observadas.

. Dentre esses modelos, destacam-se as Redes Neurais Artificiais (RNA) que consistem em uma rede de neurônios artificiais interconectados que são treinados para realizar tarefas específicas, como a classificação ou previsão (Almikaeel *et al.*, 2022).

No contexto do Estado de Mato Grosso, onde os conflitos pelo uso dos recursos hídricos se intensificam devido à expansão do agronegócio e ao rápido crescimento urbano, estudos têm buscado soluções eficazes para a previsão de vazão.

Nesse cenário, a busca por soluções eficazes para a previsão de vazões torna-se cada vez mais relevante. A adoção de modelos preditivos mais robustos é fundamental para subsidiar a tomada de decisões estratégicas e minimizar os impactos associados à competição entre os diversos usos da água como o abastecimento público, a irrigação, a dessedentação animal, a geração de energia e o transporte hidroviário (Peixoto *et al.*, 2021).

A Bacia Hidrográfica do Rio Itiquira está situada na Bacia do Rio Paraguai, especificamente na Unidade de Planejamento e Gestão (UPG) 6 Correntes-Taquari, na Região do Alto Paraguai. A Bacia do Rio Paraguai apresenta importância singular no contexto da gestão dos recursos hídricos, por incluir uma das maiores extensões de áreas alagadas do planeta: o Pantanal, declarado Patrimônio Nacional pela Constituição Brasileira de 1988, sítio designado como área de relevante importância internacional pela Convenção de Áreas Úmidas RAMSAR, no ano de 1993, e Reserva da Biosfera pela UNESCO, no ano de 2000 (ANA, 2018).

Dada a importância da gestão de recursos hídricos em regiões de expansão urbana e agrícola, especialmente devido ao impacto que essas atividades podem ter sobre ecossistemas sensíveis, como o Pantanal, é fundamental buscar o equilíbrio entre as necessidades humanas e a preservação dos recursos hídricos. Nesse contexto, a presente pesquisa propôs a utilização e a avaliação do desempenho do modelo de Redes Neurais Artificiais para previsão de vazões médias mensais para a Bacia Hidrográfica do Rio Itiquira (BHRI).

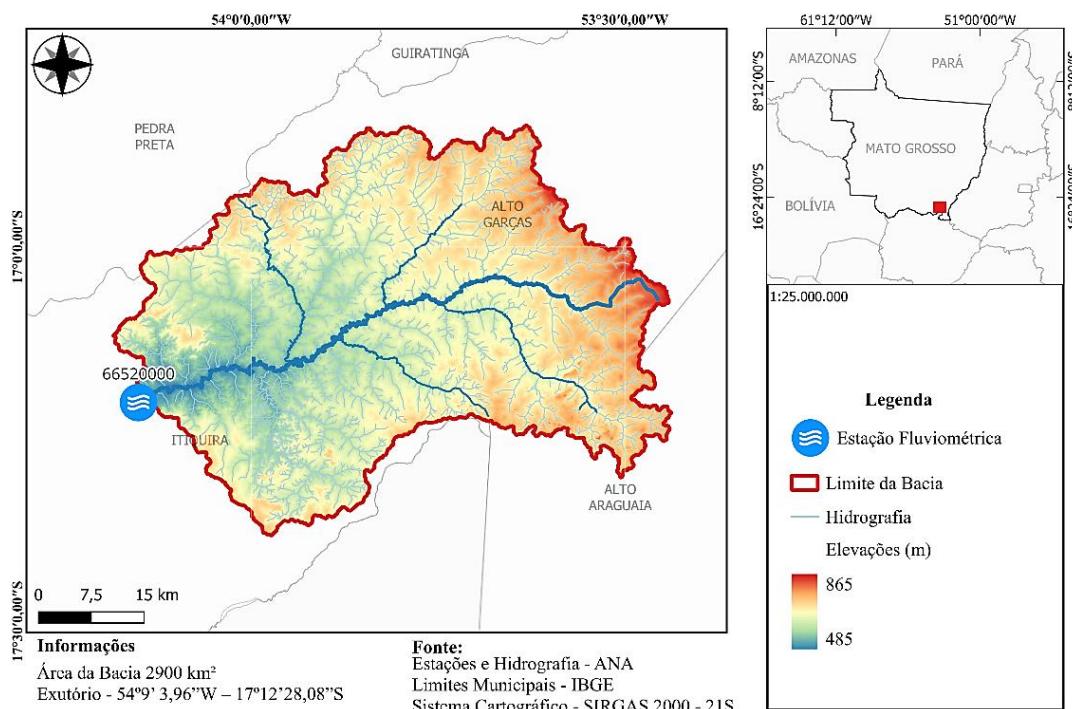
## MATERIAIS E MÉTODOS

O estudo foi realizado na Bacia Hidrográfica do Rio Itiquira (BHRI), um dos afluentes do Pantanal Mato-grossense, tendo como exutório a estação Fluviométrica Itiquira (Código 6652000) de coordenadas  $54^{\circ}9' 3,96''$  W e  $17^{\circ}12'28,08''$  S, com área de contribuição de  $2.920 \text{ km}^2$  (Figura 1). O exutório está localizado dentro da área urbana do município de Itiquira.

Para este estudo, foram utilizados dados de médias mensais de vazão, fornecidos pela Agência Nacional de Águas e Saneamento Básico (ANA) disponíveis através plataforma Hidroweb.

O monitoramento no local teve início em abril de 1971, e os dados mensais da série histórica analisada correspondem ao período de janeiro de 1984 a dezembro de 2019. O recorte temporal adotado sem lacunas foi definido com base na disponibilidade de dados de vazão.

Figura 1. Localização e delimitação da BHRI, estação fluviométrica e altimetria.



A *Multilayer Perceptron* (MLP) é um tipo de rede neural *feed-forward* que mapeia dados sujeitos às relações não lineares de entradas para saídas. Esta rede pode ter um único nó ou vários nós que formam uma camada de saída, e ter camadas intermediárias adicionais entre a camada de entrada e a camada de saída, chamadas camadas ocultas. No presente estudo, foram testadas quatro configurações de camadas ocultas, a saber: três camadas com iguais números de neurônios: (50, 50, 50), (80, 80, 80); três camadas com distintos números de neurônios (144, 72, 36) e quatro camadas com distintos números de neurônios (128, 64, 32, 16). A taxa de aprendizado foi definida em 0,01 e 0,05. Para a otimização dos pesos, utilizaram-se os algoritmos de otimização Adam (Kingma; Lei Ba, 2015) e L-BFGS (Zhu *et al.*, 1997). Por fim, as funções de ativação avaliadas foram ReLU e tanh. A Figura 3 apresenta a estrutura do modelo MLP.

Para a definição dos dados de entrada-saída, adotou-se a abordagem hold-out, na qual a série temporal foi dividida em dois conjuntos sem alteração na ordem dos dados: 80% dos dados para treinamento e 20% para testes. Essa divisão preserva a estrutura temporal da série, uma vez, a dependência temporal é fundamental para a previsão de vazão.

## Métricas de Desempenho

Neste estudo, a análise de desempenho dos modelos foi realizada por meio da utilização das métricas: Nash-Sutcliffe (NSE), Kling-Gupta (KGE) e Raiz do Erro Médio Quadrático (RMSE), descritos na Tabela 1.

Tabela 1. Métricas utilizadas para avaliar o desempenho de modelos. Adaptada de Ferreira *et al.* (2020).

Equação	Mínimo, máximo e ótimo	Unidade	Referência
$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_S)^2}{\sum_{i=1}^n (Q_{obs} - \bar{Q}_{obs})^2}$	-∞, 1, 1	-	Wohling <i>et al.</i> (2013)
$KGE = 1 - \sqrt{(r-1)^2 + (\alpha-1)^2 + \left(\frac{\bar{Q}_S}{\bar{Q}_{obs}} - 1\right)^2}$	-∞, 1, 1	-	Wohling et al. (2013)
$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_S - Q_{OBS})^2}{n}}$	0, ∞, 0	m³/s	Romanowicz <i>et al.</i> (2013)

Em que:  $Q_S$  = vazão simulada,  $Q_{obs}$  = vazão observada,  $n$  = quantidade de dados.

## RESULTADOS

A Tabela 2 apresenta as medidas descritivas dos dados de vazão, obtida a partir de 432 observações.

A vazão apresentou média de 62,09 m³/s, com erro padrão de 1,32, indicando boa precisão na estimativa da média. A mediana foi de 55,10 m³/s, próxima à média, enquanto o desvio padrão de 27,48 evidencia uma variabilidade considerável nos valores registrados. A assimetria positiva (1,15) e a curtose de 1,68 sugerem uma distribuição assimétrica à direita. Os valores variaram de 23,60 m³/s a 185,00 m³/s, com amplitude de 161,40 m³/s.

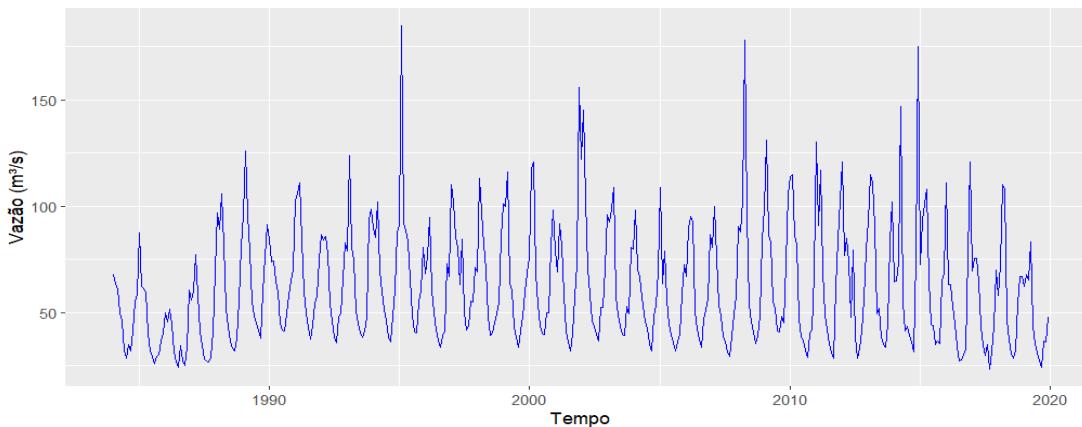
Tabela 2. Medidas descritivas da variável vazão em estudo.

Medida Descritiva	Vazão (m³/s)
Média	62,09
Erro padrão	1,32
Mediana	55,10
Desvio padrão	27,48
Variância da amostra	755,30
Curtose	1,68
Assimetria	1,15
Mínimo	23,60
Máximo	185,00

Fonte: Os autores, 2024.

A Figura 2 apresenta a série temporal de vazão de 1985 a 2020. Observa-se na série, forte sazonalidade, com picos frequentes durante os períodos de cheia, especialmente nos meses de maior precipitação, e uma queda para cerca de 50 m³/s durante a estiagem.

Figura 2. Estrutura das séries de vazão de 1985 a dezembro de 2020.



Fonte: Os autores, 2025.

Quanto ao modelo MLP, a Tabela 3 apresenta o resumo dos parâmetros para o melhor modelo obtido dentre as combinações testadas considerando diferentes horizontes de previsão (3, 6, 9 e 12 meses). O modelo de melhor desempenho considerou uma arquitetura de três camadas ocultas (144, 72 e 36 neurônios) e uma taxa de aprendizado inicial de 0,01, com a função de otimização L-BFGS e a função de ativação ReLU.

Tabela 3. Resumo dos parâmetros e desempenho dos modelos MLP para diferentes horizontes de previsão

Horizonte de Previsão	Tamanho do Conj. Treino	Tamanho do Conj. Teste	Camadas Ocultas	Taxa de Aprendizado Inicial	Função de Otimização	Ativação
3 meses	429	3	(144, 72, 36)	0,01	L-BFGS	ReLU
6 meses	426	6	(144, 72, 36)	0,01	L-BFGS	ReLU
9 meses	423	9	(144, 72, 36)	0,01	L-BFGS	ReLU
12 meses	420	12	(144, 72, 36)	0,01	L-BFGS	ReLU

Fonte: Os autores, 2025. Legenda: L-BFGS - Limited-memory Broyden-Fletcher-Goldfarb-Shanno; Relu: Rectified Linear Unit.

Acerca das funções de ativação empregadas neste trabalho, Han *et al.* (2021) destacaram o uso da função de ativação ReLU em todas as camadas do modelo LSTM, destacando sua eficiência em acelerar o treinamento e melhorar a precisão das previsões de vazão. No referido trabalho, a ReLU foi considerada superior às funções tradicionais, como tanh e sigmoide, devido à sua capacidade de evitar o problema do desaparecimento de gradiente em redes neurais profundas.

Tabela 4. Métricas de desempenho dos modelos em relação aos cenários proposto.

Horizonte de Previsão	Treino				Teste			
	RMSE	MSE	NSE	KGE	RMSE	MSE	NSE	KGE
<b>3 meses</b>	0,012	0,000	0,999	0,999	0,009	0,000	0,999	0,99990
<b>6 meses</b>	0,016	0,013	0,999	0,999	0,022	0,000	0,999	0,9995
<b>9 meses</b>	0,012	0,000	0,999	0,999	0,020	0,000	0,999	0,9995
<b>12 meses</b>	<b>0,008</b>	<b>0,000</b>	<b>0,999</b>	<b>0,999</b>	<b>0,013</b>	<b>0,000</b>	<b>0,999</b>	<b>0,9997</b>

Fonte: Os autores, 2025

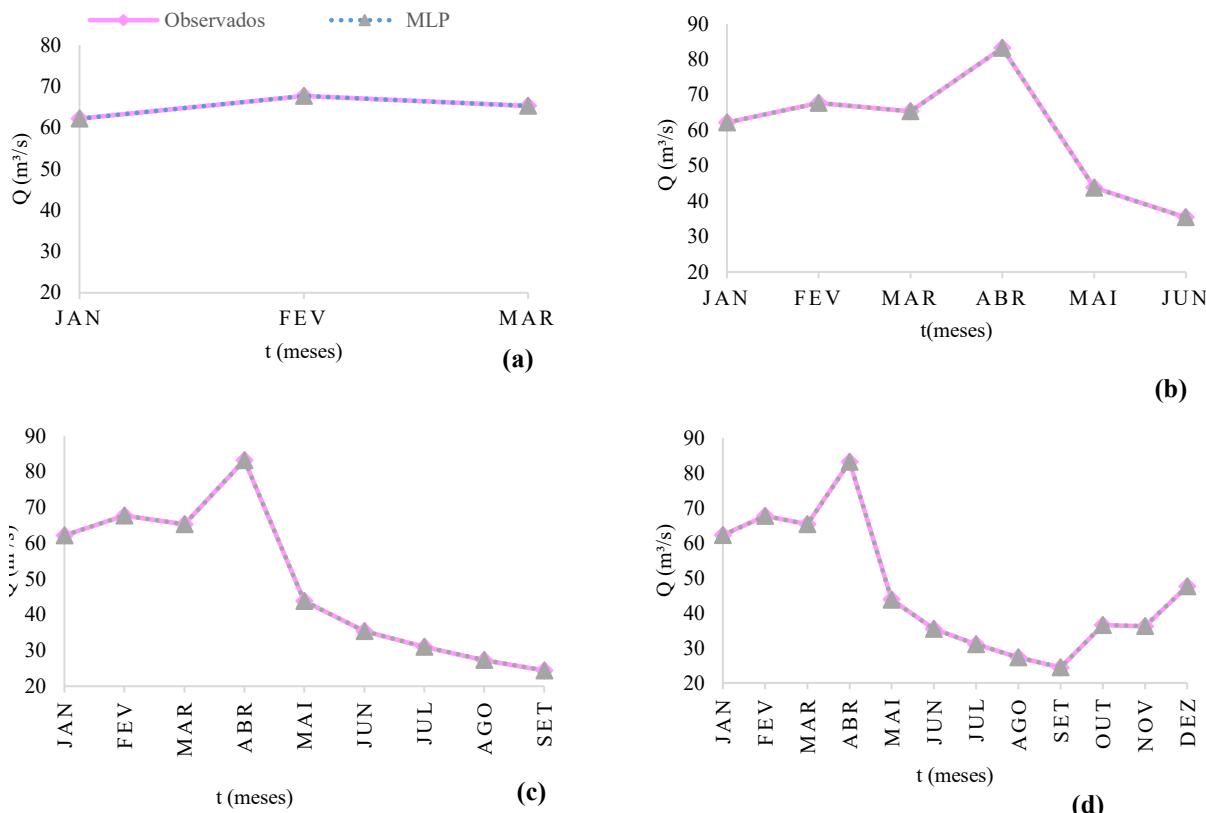
Diversos estudos reforçam a eficácia das redes neurais na modelagem hidrológica (Lujano *et al.*, 2023; Mao *et al.*, 2021; Brandão *et al.*, 2024; Ramos Filho *et al.*, 2024). Bouix (2024), por exemplo, ao aplicar um modelo MLP na previsão de vazões médias mensais no rio Miranda (bacia do rio Paraguai), obteve RMSE de 23,04% nos períodos de treino e validação, e 32,98% no teste, utilizando

uma rede com sete neurônios em uma camada oculta e função de ativação ReLU. O autor destaca que o desempenho do modelo depende fortemente da escolha da arquitetura e dos hiperparâmetros.

Neste contexto, o presente trabalho se destaca por alcançar um RMSE de 0,008% no treino e 0,013% no teste. Isso evidencia que, com uma arquitetura bem ajustada, é possível obter resultados precisos, reafirmando o potencial das redes neurais MLP na previsão de vazões.

A Figura 3 ilustra o desempenho satisfatório da MLP para o horizonte de previsão, capturando refletindo variações sazonais e valores de máxima e mínima observadas.

Figura 3. Comparação entre valores observados e previstos pelo modelo MLP para diferentes horizontes de previsão: 3 meses (a), 6 meses (b), 9 meses (c) e 12 meses (d)



Fonte: Os autores, 2025. Legenda:  $Q$  – Vazão em  $\text{m}^3/\text{s}$ ;  $t$  – tempo em meses.

## CONCLUSÃO

Este trabalho analisou o desempenho do modelo MLP na previsão de vazões médias mensais em diferentes horizontes de tempo, com foco na precisão das previsões e na eficiência dos modelos. Os resultados demonstraram que o modelo MLP, mesmo utilizando apenas a série histórica de vazões como entrada foi eficiente para previsão de vazões médias mensais.

Dessa forma, este estudo conclui que o uso de redes neurais artificiais, como o MLP, como um grande avanço para a previsão de vazão, especialmente em cenários hidrológicos onde a disponibilidade de dados é limitada.

Para trabalhos futuros, sugere-se a aplicação do modelo MLP em outras bacias hidrográficas, visando verificar a capacidade de generalização em diferentes condições hidrológicas. Além disso, destaca-se a importância de aprimorar a previsão de eventos extremos, como vazões mínimas e

máximas, implementando técnicas específicas de aprendizado profundo para garantir maior precisão em situações de secas e inundações. Por fim, sugere-se a avaliação do impacto temporal nas previsões, considerando a variabilidade sazonal e as mudanças climáticas, com a aplicação de cenários de longo prazo.

## REFERÊNCIAS

- ALMIKAEEL, W.; ČUBANOVÁ, L.; ŠOLTÉSZ, A (2022). *Hydrological Drought Forecasting Using Machine Learning—Gidra River Case Study*. Water, v. 14, n. 3, p. 387. <https://doi.org/10.3390/w14030387>.
- AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO – ANA (2018). *Plano de Recursos Hídricos da Região Hidrográfica do Paraguai – PRH Paraguai: Resumo Executivo / Agência Nacional de Águas*. Brasília.
- BOUIX, C. P. S (2024). *Modelagem de Redes Neurais Artificiais MLP para previsão de vazões na bacia do rio Miranda afluente do Pantanal*. Dissertação (Mestrado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.
- BRANDÃO, A. R. A.; MENEZES FILHO, F. C. M.; OLIVEIRA, P. T. S.; FAVA, M. C. (2024). *Artificial neural networks applied for flood forecasting in ungauged basin – the Paranaíba river study case*, Proc. IAHS, 386, 81–86, <https://doi.org/10.5194/piahs-386-81-2024>.
- FERREIRA, P. M. D. L.; PAZ, A. R. D.; BRAVO, J. M (2020). *Objective functions used as performance metrics for hydrological models: state-of-the-art and critical analysis*. RBRH, v. 25, p. e42. <https://doi.org/10.1590/2318-0331.252020190155>.
- HAN, H.; CHOI, C.; JUNG, J.; KIM, H. S (2021). *Deep Learning with Long Short Term Memory Based Sequence-to-Sequence Model for Rainfall-Runoff Simulation*. Water, v. 13, n. 4, p. 437. <https://doi.org/10.3390/w13040437>.
- KINGMA, D. P.; LEI BA, J (2015). *Adam: A method for stochastic optimization*. Conference paper at the 3rd International Conference for Learning Representations.
- LUJANO, E., LUJANO, R., HUAMANI, J. C., LUJANO, A. (2023). *Hydrological modeling based on the KNN algorithm: An application for the forecast of daily flows of the Ramis river, Peru*. *Tecnología Y Ciencias Del Agua*, 14(2), 169–203. <https://doi.org/10.24850/j-tyca-14-02-05>
- MAO, G.; WANG, M.; LIU, J.; WANG, Z.; WANG, K.; MENG, Y.; ZHONG, R.; WANG, H.; LI, Y (2021). *Comprehensive comparison of artificial neural networks and long short-term memory networks for rainfall-runoff simulation*. Physics and Chemistry of the Earth, Parts A/B/C, v. 123, p. 103026. <https://doi.org/10.1016/j.pce.2021.103026>.
- NAGANNA, S. R.; MARULASIDDAPPA, S. B.; BALREDDY, M. S.; YASEEN, Z. M (2023). *Daily scale streamflow forecasting in multiple stream orders of Cauvery River, India: Application of advanced ensemble and deep learning models*. Journal of Hydrology, v. 626, p. 130320. <https://doi.org/10.1016/j.jhydrol.2023.130320>.
- NGUYEN, T.-T.-H.; VU, D.Q.; MAI, S. T.; DANG, T. D (2023). *Streamflow Prediction in the Mekong River Basin Using Deep Neural Networks*. IEEE Access, v. 11, p. 97930–97943. <https://doi.org/10.1109/ACCESS.2023.3301153>.

PEIXOTO, F. D. S.; SOARES, J. A.; RIBEIRO, V. S (2021). *Conflitos pela água no Brasil. Sociedade & Natureza*, v. 34, n. 1. DOI 10.14393/SN-v34-2022-59410. Disponível em: <https://seer.ufu.br/index.php/sociedadenatureza/article/view/59410>.

RAMOS FILHO, H.A., ULIANA, E.M., AIRES, U.R.V. DA FANTIN-CRUZ, I. LISBOA, L., SILVA, D.D., VIOLA, M.R, DUARTE,V.B.R (2024). *Nowcast flood predictions in the Amazon watershed based on the remotely sensed rainfall product PDIRnow and artificial neural networks.* Environ Monit Assess 196, 245. <https://doi.org/10.1007/s10661-024-12396>-

ROMANOWICZ, R. J.; OSUCH, M.; GRABOWIECKA, M (2013). *On the choice of calibration periods and objective functions: a practical guide to model parameter identification.* Acta Geophysica, 61(6), 1477-1503. <http://dx.doi.org/10.2478/s11600-013-0157-6>.

SHAH, H. S. M.; YASSIN, M. A.; ABBA, S. I.; LAWAL, D. U.; HUSSEIN AL-QADAMI, E. H.; TEO, F. Y.; MUSTAFFA, Z.; ALJUNDI, I. H (2023). *Flood Risk and Vulnerability from a Changing Climate Perspective: An Overview Focusing on Flash Floods and Associated Hazards in Jeddah.* Water, v. 15, n. 20, p. 3641. <https://doi.org/10.3390/w15203641>.

SIQUEIRA, F. B (2021). *Conflitos de Usos Múltiplos dos Recursos Hídricos e Reservatórios Hidrelétricos no Brasil.* Tese de doutorado, Universidade Federal do Rio de Janeiro, Programa de Planejamento Energético, COPPE, Rio de Janeiro.

WOHLING, T.; SAMANIEGO, L.; KUMAR, R (2013). Evaluating multiple performance criteria to calibrate the distributed hydrological model of the upper Neckar catchment. Environmental Earth Sciences, 69(2), 453-468. <http://dx.doi.org/10.1007/s12665-013-2306-2>.

ZHU, C.; BYRD,R.H.; LU P.,; NOCEDAL, J (1997). *Algorithm 778: L-BFGS-B: Fortran subroutines for large-scale bound-constrained optimization.* ACM transactions on mathematical software. Association for Computing Machinery, v. 23, n. 4, p. 550–560.

## AGRADECIMENTOS

Agradecemos ao Programa de Pós-graduação em Recursos Hídricos (PPGRH) e a Universidade Federal de Mato Grosso (UFMT) pelo apoio à pesquisa