

APRENDIZADO PROFUNDO PARA PREVISÃO HIDROLÓGICA: ESTUDO DE CASO NA BACIA DO RIO MIRANDA

Ana Paula Lapas Leão¹, Ariel Ortiz Gomes²

RESUMO

Este estudo, alinhado à linha de pesquisa “Ferramentas Aplicadas aos Instrumentos de Gestão de Recursos Hídricos”, avaliou o potencial da arquitetura de rede neural Long Short-Term Memory (LSTM) como ferramenta de apoio à decisão para a gestão de recursos hídricos. O objetivo foi analisar sua capacidade de prever vazões em bacia hidrográfica com foco em eventos de seca. Para isso, foi desenvolvida uma metodologia com pré-processamento de 30 anos de dados hidrometeorológicos da Bacia do Rio Miranda. O modelo LSTM foi treinado com 75 épocas e avaliado por métricas estatísticas, como Coeficiente de Nash-Sutcliffe (NSE) e Coeficiente de Determinação (R^2). Os resultados, com um NSE de 0,6926, demonstraram alta precisão do modelo na simulação de vazões mínimas e um viés de erro baixo. Embora o modelo tenha apresentado limitações na previsão de picos de cheia, sua robustez para cenários de escassez hídrica valida sua aplicabilidade. A pesquisa contribui diretamente para a meta 6.4 da ODS 6: Água Limpa e Saneamento, reforçando o potencial da LSTM como ferramenta promissora para a mitigação dos impactos de secas.

PALAVRAS-CHAVE: Gestão de Recursos Hídricos. LSTM. Vazões Mínimas.

ABSTRACT

This study, aligned with the research line “Tools Applied to Water Resources Management Instruments,” evaluated the potential of the Long Short-Term Memory (LSTM) neural network architecture as a decision support tool for water resources management. The objective was to analyze its ability to predict flows in a river basin with a focus on drought events. For this, a methodology was developed with the preprocessing of 30 years of hydrometeorological data from the Miranda River Basin. The LSTM model was trained for 75 epochs and evaluated using statistical metrics such as the Nash-Sutcliffe Efficiency Coefficient (NSE) and Coefficient of Determination (R^2). The results, with an NSE of 0.6926, demonstrated the model's high precision in simulating minimum flows and a low error bias. Although the model showed limitations in predicting flood peaks, its robustness for water scarcity scenarios validates its applicability. The research directly contributes to target 6.4 of SDG 6: Clean Water and Sanitation, reinforcing the potential of LSTM as a promising tool for mitigating the impacts of droughts.


KEYWORDS: Water Resources Management. LSTM. Minimum Flows.

INTRODUÇÃO

A gestão eficiente dos recursos hídricos é um desafio urgente do século XXI, agravado por eventos de seca (PISSARRA et al., 2017). No Brasil, o gerenciamento é formalizado pela Lei nº 9.433/1997, a Lei das Águas, que busca garantir a disponibilidade hídrica. A previsão de vazões é

¹ Aluna da Universidade Estadual de Mato Grosso do Sul. Ferramentas Aplicadas aos Instrumentos de Gestão de Recursos Hídricos. Campo Grande, MS, Brasil. E-mail: anapaulalapas@gmail.com.

² Docente no Programa de Mestrado Profissional de Gestão e Regulação de Recursos Hídricos (PROFAGUA). Universidade Federal de Mato Grosso do Sul. Campo Grande, MS, Brasil. E-mail: ariel.gomes@ufms.br



crucial para este planejamento e está alinhada com a ODS 6, meta 6.4, que visa a eficiência no uso da água para enfrentar a escassez (NAÇÕES UNIDAS BRASIL, 2022). O uso de modelos de aprendizado de máquina surge como uma alternativa aos modelos hidrológicos tradicionais, que apresentam limitações em bacias complexas (WANG et al., 2020; CHEN et al., 2019). A arquitetura Long Short-Term Memory (LSTM) destaca-se na previsão de vazões por sua capacidade de aprender com dependências de longo prazo (HOCHREITER; SCHMIDHUBER, 1997; LIU; ZENG; HE, 2023). Apesar do sucesso em simulações gerais, prever eventos extremos como as secas continua sendo um desafio devido à baixa frequência desses dados (LIU et al., 2020). Este estudo avalia o potencial da LSTM na Bacia Hidrográfica do Rio Miranda, focando na sua aplicação como ferramenta de apoio à decisão para a gestão de recursos hídricos em cenários de escassez.

MÉTODOS


A metodologia compreendeu a coleta e o pré-processamento de 30 anos de dados hidrológicos da Bacia do Rio Miranda, obtidos da Rede Hidrometeorológica Nacional (RHN). Os dados brutos foram pré-processados, com o preenchimento de lacunas via regressão linear e a normalização dos valores para o intervalo de 0 a 1 usando o algoritmo MinMaxScaler. A janela temporal foi definida com 30 dias, e os dados foram divididos em 80% para treinamento e 20% para teste. O modelo LSTM foi desenvolvido com a biblioteca TensorFlow/Keras, consistindo em uma camada de entrada, uma camada LSTM com 50 neurônios e uma camada de saída densa. O treinamento foi executado por 75 épocas com o otimizador Adam e a função de perda Mean Squared Error (MSE). O desempenho foi avaliado com métricas estatísticas como RMSE, R^2 , NSE e PBIAS.

RESULTADOS E DISCUSSÕES

O modelo LSTM alcançou um desempenho satisfatório no conjunto de teste. As métricas obtidas foram: RMSE: 17,12 m³/s, R^2 : 0,6926, NSE: 0,6926, PBIAS: 0,72%, MAPE: 12,37% e CE: 0,8526, indicando um bom ajuste e ausência de viés sistemático. A análise da Curva de Permanência (Figura 1) revelou uma sobreposição quase perfeita das curvas de vazão observada e simulada em períodos de vazões baixas, evidenciando a precisão do modelo na simulação do comportamento de vazões mínimas.


O hidrograma de vazões, ilustrado na figura "Comparação entre vazão real e prevista no conjunto de teste", mostra que o modelo replicou a dinâmica geral do rio, com notável acurácia em vazões médias e baixas, embora tenha subestimado picos de cheia. A análise do período de seca confirma a adequação do modelo, pois a maioria dos erros de previsão para esse período é de baixa magnitude, reforçando a sua confiabilidade. A pequena magnitude dos erros durante a seca indica que o modelo pode ser uma ferramenta valiosa de apoio à decisão para o planejamento e a gestão de recursos hídricos, auxiliando na alocação de água e na mitigação dos efeitos da seca (DE LIMA et al., 2021).

Figura 1 – Curva de Permanência (Flow Duration Curve) das vazões observadas e simuladas.



Fonte: Autores (2025).


Figura 2 – Comparação entre vazão real e prevista no conjunto de teste.



Fonte: Autores (2025).

CONCLUSÃO

Este estudo avaliou o potencial da arquitetura de Rede Neural Artificial do tipo LSTM na previsão de vazões em uma bacia hidrográfica com dinâmicas complexas, com foco especial na simulação de eventos de seca. Os resultados demonstram que o modelo LSTM é uma ferramenta promissora e eficaz para este propósito, superando desafios comuns enfrentados por modelos hidrológicos tradicionais. As métricas de desempenho globais indicaram um desempenho satisfatório, e a análise de vazões mínimas validou a robustez do modelo em cenários de escassez. Embora o modelo tenha demonstrado uma tendência a subestimar picos de cheia, essa limitação é amplamente compensada por sua alta acurácia nas previsões de vazão mínima, que era o foco principal do estudo.



AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e da Agência Nacional de Águas e Saneamento Básico (ANA) através do Convênio CAPES/UNESP Nº. 951420/2023. Agradeço ao Programa de Mestrado Profissional em Rede Nacional em Gestão e Regulação de Recursos Hídricos - ProfÁgua pelo apoio técnico científico aportado até o momento.

REFERÊNCIAS

- AGHAJANI, S. et al. Artificial Neural Networks for rainfall-runoff modeling: a review. *Journal of Water Resource and Protection*, v. 10, n. 11, p. 1101-1115, 2018. Disponível em: <https://doi.org/10.4236/jwarp.2018.1011065>. Acesso em: 18 ago. 2025.
- CARVALHO, K. Q.; LIMA, S. B.; PASSIG, F. H.; et al. Influence of urban area on the water quality of the Campo River basin, Paraná state, Brazil. **Brazilian Journal of Biology**, v. 75, n. 4, 2015.
- CHEN, C. et al. A review of hydrological forecasting models based on machine learning. *Journal of Hydrology*, v. 574, p. 1-15, 2019. Disponível em: <https://doi.org/10.1016/j.jhydrol.2019.04.053>. Acesso em: 18 ago. 2025.
- DE LIMA, M. L. et al. Deep learning approaches for short-term water level forecasting in urban areas. *Journal of Hydrology*, v. 598, 2021. Disponível em: <https://doi.org/10.1016/j.jhydrol.2021.126388>. Acesso em: 18 ago. 2025.
- DONINELLI, J. W.; SILVA, R. V. Modelo de previsão de vazões por meio de rede neural LSTM. In: *Anais do XXX Congresso Nacional de Recursos Hídricos*, 2025. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=14874>. Acesso em: 18 ago. 2025.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, n. 8, p. 1735-1780, 1997. Disponível em: <https://doi.org/10.1162/neco.1997.9.8.1735>. Acesso em: 18 ago. 2025.
- KIM, M.; VALYRAKISTH, G. A review of deep learning models for streamflow forecasting. *Journal of Hydrology*, v. 602, 2021. Disponível em: <https://doi.org/10.1016/j.jhydrol.2021.126868>. Acesso em: 18 ago. 2025.
- LIU, J. et al. A hybrid deep learning approach for daily streamflow forecasting in a tropical river basin. *Journal of Hydrology*, v. 586, p. 1-13, 2020.
- LIU, Y.; ZENG, Y.; HE, Z. Rainfall-runoff forecasting using a hybrid model of attention mechanism and LSTM. *Water Resources Management*, v. 37, p. 2731-2748, 2023.
- MENDES, A. C.; SOUZA, P. J. Seca e gestão de recursos hídricos no Brasil. *Cadernos de Ciência e Tecnologia*, v. 35, n. 1, p. 125-139, 2018. Disponível em: <https://doi.org/10.1590/0104-569056>. Acesso em: 18 ago. 2025.
- MENDES, A. L. Pré-processamento de Dados para Machine Learning.