

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

PREVISÃO DE VAZÕES COM REDES NEURAIS DO TIPO MLP: ESTUDO DE CASO NA SUB-BACIA DO RIO PIRACICABA (MG)

Taís Fonte Boa de Campos Maia¹; Marina Marcela de Paula Kolanski²; André Ferreira Rodrigues³; Bruno Melo Brentan⁴ & Gustavo Meirelles Lima⁵.

Abstract: Artificial neural networks are computational models capable of learning from data and making predictions. This study aimed to evaluate the application of a specific neural network model, the Multilayer Perceptron (MLP), for streamflow forecasting in the Piracicaba River basin, located in the state of Minas Gerais, Brazil. The MLP is characterized by its architecture composed of multiple layers of artificial neurons, which allows it to model nonlinear relationships between variables. The modeling was based on data from nine hydrometeorological stations operated by the Agência Nacional de Águas e Saneamento Básico (ANA). The neural network is implemented in Python, using libraries such as PyTorch and Scikit-learn, and tested across different architectures with various combinations of neurons and hidden layers. Model performance is evaluated for two forecasting horizons—1 and 7 days—using the statistical metrics MAE (Mean Absolute Error), RMSE (Root Mean Square Error), NSE (Nash-Sutcliffe Efficiency), and PBIAS (Percent Bias). The MLP model demonstrated satisfactory performance for the 1-day forecast horizon (MAE = 13.93 m³/s; NSE = 0.90), but showed reduced accuracy for the 7-day horizon, particularly during high-flow events. This suggests limitations in the model's ability to capture hydrological peaks.

Resumo: Redes neurais são modelos computacionais capazes de aprender e fazer previsões a partir de dados. Este estudo teve como objetivo avaliar a aplicação de um modelo específico de rede neural, o Perceptron Multicamadas (MLP – Multilayer Perceptron), na previsão de vazões na bacia hidrográfica do Rio Piracicaba, localizada no estado de Minas Gerais. A modelagem foi fundamentada em 9 estações hidrometeorológicas da Agência Nacional de Águas e Saneamento Básico (ANA). A rede neural foi implementada em ambiente Python, utilizando bibliotecas como PyTorch e Scikit-learn, e testada em diferentes arquiteturas com combinações variadas de neurônios e camadas ocultas. A avaliação do desempenho do modelo considerou dois horizontes diferentes de previsão, 1 e 7 dias, e foi realizada com base nas métricas estatísticas MAE (Erro Absoluto Médio), RMSE (Raiz do Erro Quadrático Médio), NSE (Eficiência de Nash-Sutcliffe) e PBIAS (Tendência de Viés Percentual). O modelo MLP apresentou desempenho satisfatório para horizontes de previsão de 1 dia (MAE = 13,93 m³/s; NSE = 0,90), mas desempenho reduzido em horizontes de 7 dias,

1) SMARH - Universidade Federal de Minas Gerais (UFMG), Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG. 31270-901, taisfb10@ufmg.br

2) SMARH - Universidade Federal de Minas Gerais (UFMG), Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG. 31270-901, mkolanski@ufmg.br

3) SMARH - Universidade Federal de Minas Gerais (UFMG), Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG. 31270-901, afrodrigues@ehr.ufmg.br

4) SMARH - Universidade Federal de Minas Gerais (UFMG), Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG. 31270-901, brentan@ehr.ufmg.br

5) SMARH - Universidade Federal de Minas Gerais (UFMG), Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG. 31270-901, gustavo.meirelles@ehr.ufmg.br

principalmente em eventos de alta vazão, sugerindo limitações na capacidade do modelo em capturar picos hidrológicos.

Palavras-Chave – Previsão Hidrológica, Redes neurais, MLP.

INTRODUÇÃO

A previsão de vazões é fundamental para a gestão dos recursos hídricos, principalmente frente as mudanças climáticas e a ocorrência de eventos extremos, como enchentes e secas. Antecipar o comportamento dos regimes fluviais é essencial para a operação de reservatórios, controle de inundações, abastecimento público e tomada de decisão em tempo real.

Nos últimos anos, métodos baseados em aprendizado de máquina têm ganhado destaque na modelagem hidrológica, sobretudo em virtude de sua capacidade de lidar com relações não lineares e com múltiplas variáveis de entrada. Entre esses métodos, as Redes Neurais vêm sendo amplamente aplicadas na previsão de vazões, demonstrando resultados promissores em diversos estudos (YU et al., 2024; BOUIX, 2024). Em particular, a arquitetura Perceptron Multicamadas (MLP – Multilayer Perceptron) se destaca por conseguir identificar padrões complexos e não lineares (LIPPMANN, 1987).

O presente estudo tem como objetivo avaliar o desempenho de um modelo de rede neural do tipo MLP na previsão de vazões em dois horizontes distintos (1 e 7 dias), com base em dados hidrometeorológicos. A análise do desempenho foi conduzida por meio de métricas estatísticas, com o intuito de verificar tanto a eficácia quanto as limitações do modelo.

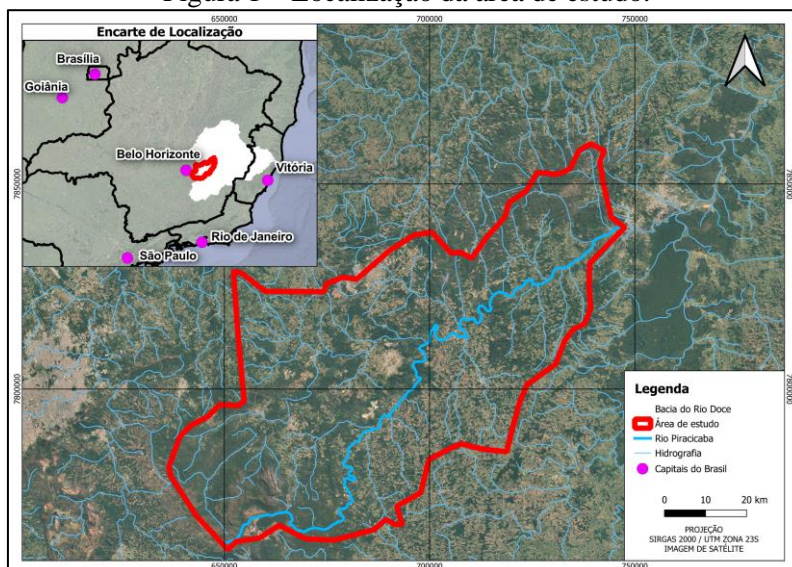
Área de estudo

A área de estudo está situada na região Sudeste do Brasil, no estado de Minas Gerais, a aproximadamente 45 km de Belo Horizonte. Trata-se de uma sub-bacia de cabeceira pertencente à bacia hidrográfica do rio Doce (Figura 1). O principal curso d'água da região é o rio Piracicaba, com uma extensão de 189,2 km no trecho analisado, exercendo papel fundamental no abastecimento hídrico, em atividades de irrigação e na geração de energia elétrica.

Na área do estudo, encontram-se instaladas seis Pequenas Centrais Hidrelétricas (PCHs): Antônio Dias, Cocaís Grande, São Gonçalo, Taquari, Quenta Sol e Rio Piracicaba; duas Centrais Geradoras Hidrelétricas (CGHs): Antônio Dias e Barra; e quatro Usinas Hidrelétricas (UHEs): Guilman Amorim, Sete Moínhos, Peti, Sá Carvalho e Cachoeira Fábrica Velha (ANEEL, 2016).

O substrato geológico predominante abrange as unidades Serra Negra de Guanhães, Belo Horizonte e Santo Antônio do Pirapetinga, compostas majoritariamente por gnaisses e xistos básicos, típicos de ambientes com rochas metamórficas e sedimentares metamorfizadas. O solo dominante é o Latossolo Vermelho-Amarelo distrófico, caracterizado por elevada acidez, baixa fertilidade, alta permeabilidade e reduzida capacidade de retenção hídrica (EMBRAPA, 2018). Quanto ao uso e ocupação do solo, prevalecem áreas de pastagem e vegetação nativa (MAPBIOMAS, 2024).

Figura 1 – Localização da área de estudo.



Estações de monitoramento

Foram utilizadas séries históricas de estações pluviométricas, fluviométricas e meteorológica localizadas na sub-bacia do rio Piracicaba, com dados extraídos da plataforma Hidroweb (ANA) e do INMET. A seleção das séries considerou registros diários com, no mínimo, 10 anos de duração e um percentual de falhas inferior a 10%, porém todas as estações selecionadas apresentam dados no período compreendido entre abril de 1989 e junho de 2022, totalizando 33 anos de informações utilizadas na modelagem. O método dos k-vizinhos mais próximos (KNN) foi adotado para o preenchimento de dados ausentes, por sua capacidade de preservar a coerência temporal das séries históricas. Esse algoritmo calcula os k vizinhos mais próximos e imputa o valor correspondente, para variáveis numéricas, a média dos valores é calculada (GARCÍA et al., 2015). As estações selecionadas e suas características estão apresentadas na Tabela 1.

Tabela 1 – Estações selecionadas.

Estação	Código	Nome estação	Latitude (°)	Longitude (°)	Responsável/Operadora
Fluviométrica	56610000	Rio Piracicaba	-19,93	-43,17	ANA/CPRM
	56640000	Carrapato (Brumal)	-19,97	-43,46	ANA/CPRM
	56659998	Nova Era IV	-19,77	-43,03	ANA/CPRM
	56696000	Mario de Carvalho	-19,52	-42,64	ANA/CPRM
Pluviométrica	1942029	Mario de Carvalho	-19,52	-42,64	ANA/CPRM
	1943001	Rio Piracicaba	-19,92	-43,18	ANA/CPRM
	1943007	Santa Bárbara	-19,95	-43,40	ANA/CPRM
	1943027	Usina Peti	-19,88	-43,37	ANA/CPRM
	2043059	Colégio Caraça	-20,10	-43,49	ANA/CPRM
Meteorológica	83592	Caratinga	-19,74	-42,14	INMET

METODOLOGIA

Machine learning aplicada à previsão de vazão - MLP

As redes neurais do tipo Perceptron Multicamadas (MLP) são modelos computacionais que se destacam por possuírem uma ou mais camadas intermediárias, chamadas camadas ocultas, entre as camadas de entrada e saída. O MLP consegue aprender padrões complexos e não lineares graças à presença desses neurônios ocultos (LIPPMANN, 1987). Nessas redes, os neurônios de uma camada estão totalmente conectados aos neurônios da camada seguinte, sem conexões laterais ou ciclos de realimentação. O processo de aprendizado do MLP ocorre por meio de ajustes iterativos dos pesos das conexões, guiados pela minimização do erro entre a saída prevista e a saída desejada, o que permite à rede aprimorar seu desempenho progressivamente (GONÇALVES, 2020).

Neste trabalho, o modelo MLP foi aplicado à previsão de vazões em dois horizontes temporais distintos: 1 e 7 dias à frente. A modelagem foi implementada em ambiente computacional baseado em linguagem Python, com uso de bibliotecas especializadas, como: pandas, numpy, matplotlib, pyplot, torch e torch.nn, sklearn.model_selection.train_test_split e pickle.

Como base de dados, foram utilizadas séries históricas de vazão, precipitação e temperatura, com registros entre abril de 1989 e junho de 2022, provenientes de estações fluviométricas e meteorológicas localizadas na sub-bacia do rio Piracicaba. A estação fluviométrica 56696000, situada no exutório da bacia, foi escolhida como foco da modelagem, por permitir uma análise da resposta hidrológica de toda a área de drenagem em questão. A divisão dos dados considerou 80% para treinamento e 20% para teste, respeitando a ordem cronológica e evitando sobreposição entre variáveis de entrada e saída. Para isso, foi necessário descartar as primeiras 24 horas (para horizonte de 1 dia) e 168 horas (para 7 dias) dos conjuntos de previsão.

Foram testadas diferentes arquiteturas de rede, com variações no número de camadas ocultas e de neurônios por camada, além de diferentes combinações de variáveis de entrada. O processo de treinamento foi realizado com ajuste dinâmico da taxa de aprendizado e utilização do método de early stopping, que interrompe o treinamento automaticamente quando não há melhoria significativa no desempenho do modelo, evitando o sobreajuste (overfitting).

A avaliação dos modelos foi conduzida por meio de métricas estatísticas amplamente utilizadas na literatura hidrológica, como o Erro Absoluto Médio (MAE), a Raiz do Erro Quadrático Médio (RMSE), a Eficiência de Nash-Sutcliffe (NSE) e o Viés Percentual (PBIAS), cujas definições são apresentadas na seção seguinte.

Avaliação do modelo

As métricas utilizadas para avaliação do modelo de rede neural está descrito de forma detalhada, juntamente com seus equacionamentos nos parágrafos abaixo.

O erro absoluto médio (MAE) é uma métrica que calcula a média dos erros absolutos entre os valores observados e os previstos, esta metodologia ignora o sinal do erro, assim não é possível observar se o sistema superestima ou subestima o erro. O MAE avalia o quanto o modelo se desvia dos dados reais, em média, seu valor ideal é 0. A equação 1 indica a formulação desta métrica.

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - S_i| \quad (1)$$

Sendo:

- n, o total de dados reais e previstos;
- O_i , os valores reais;
- S_i , os valores previstos.

O Nash-Sutcliffe Efficiency (NSE) é uma métrica de eficiência que mede o desempenho geral do modelo em relação à média observada. Seu valor varia de menos infinito a 1, onde 1 representa um modelo perfeito e valores próximos ou abaixo de zero, um modelo ruim. A equação 2 indica a formulação desta métrica

$$NSE = \frac{\sum_{i=1}^n (O_i - S_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (2)$$

Sendo:

- \bar{O} , a média dos valores observados.

O Percent Bias (PBIAS) mede a tendência do modelo em superestimar ou subestimar os valores observados. Os resultados positivos desta métrica indicam que o modelo subestima os dados previstos, enquanto valores negativos superestima os dados. Os valores próximos de zero indicando menor viés, o que representa uma maior precisão nas previsões. A equação 3 indica a formulação desta métrica

$$PBIAS = \frac{\sum_{i=1}^n (O_i - S_i)}{\sum_{i=1}^n O_i} * 100 \quad (3)$$

O Root Mean Square Error (RMSE) mede o erro quadrático médio entre os valores observados e simulados. Diferente do MAE, esta métrica é sensível a grandes erros, devido à elevação ao quadrado, seu valor ideal é 0. A equação 4 indica a formulação desta métrica.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - S_i)^2} \quad (4)$$

Além destas quatro métricas foram avaliados, também, os resíduos, os quais são a diferença entre o valor observado e o valor simulado pelo modelo. O valor ideal para o resíduo é zero, porém, caso este seja positivo significa que o modelo subestimou o valor observado, o oposto acontece se o valor for negativo.

RESULTADOS E DISCUSSÕES

O modelo foi avaliado com 9 combinações diferentes, considerando 3 quantidades de camadas (2, 3 e 4) e 3 números de neurônios (32, 128 e 256). Para determinar a melhor configuração, analisaram-se os resultados com base nas métricas de desempenho.

Para o horizonte de previsão de 1 dia, a combinação de 256 neurônios e 3 camadas destacou-se, alcançando 2 dos 4 melhores resultados. No caso da previsão com horizonte de 7 dias, a combinação de 128 neurônios e 4 camadas ocultas foi a que apresentou os melhores resultados, também se destacando em 2 das 4 métricas de desempenho. Dessa forma, essas arquiteturas foram adotadas para as modelagens. A Tabela 2 apresenta os resultados para cada métrica avaliada a partir das melhores combinações para ambos os horizontes.

Tabela 2 - Combinações que obtiveram os melhores resultados para as métricas.

Métrica	1 dia		7 dias	
	Combinação de camadas e neurônios	Valor	Combinação de camadas e neurônios	Valor
MAE	Neurônios: 128 Camadas: 3	13,93 m ³ /s	Neurônios: 128 Camadas: 2	32,63 m ³ /s
NSE	Neurônios: 256 Camadas: 3	0,90	Neurônios: 128 Camadas: 4	0,24
PBIAS	Neurônios: 128 Camadas: 2	5,15 %	Neurônios: 32 Camadas: 2	0,08 %
RMSE	Neurônios: 256 Camadas: 3	28,91 m ³ /s	Neurônios: 128 Camadas: 4	80,35 m ³ /s

Além disso, a Tabela 2 apresenta que as métricas de erro, como o MAE e o RMSE, são bem mais baixas no curto prazo, indicando que o modelo consegue prever com mais precisão quando o intervalo é menor. O MAE de 1 dia foi de 13,93 m³/s, enquanto para 7 dias foi mais que o dobro, com 32,63 m³/s. O mesmo acontece com o RMSE, que passou de 28,91 m³/s para 80,35 m³/s. O NSE, que mede o quão bem o modelo acompanha os dados reais, foi de 0,90 na previsão de 1 dia. Já na previsão de 7 dias, caiu para 0,24, mostrando perda de qualidade. Apesar disso, o PBIAS ficou próximo de zero nos dois casos, indicando que não houve tendência clara de superestimar ou subestimar as vazões. No geral, os resultados mostram que o modelo apresenta melhor desempenho para previsões de curto prazo.

As Figura 2 e 3 apresentam hidrogramas comparando as vazões observadas (em azul) e a vazão prevista (vermelho), da fase de teste, para as previsões de 1 e 7 dias, respectivamente.

Figura 2- Valores reais e previstos (256 Neurônios e 3 Camadas) – 1 dia - Conjunto de teste.

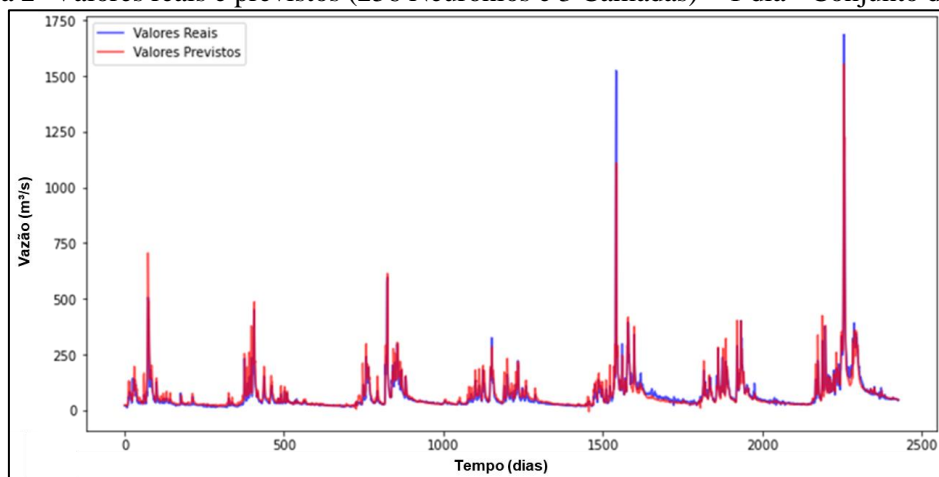
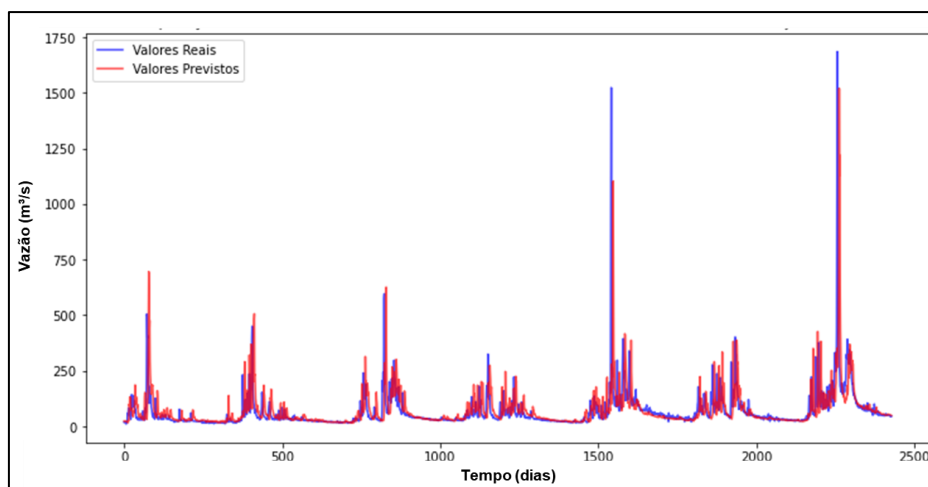


Figura 3- Valores reais e previstos (128 Neurônios e 4 Camadas) – 7 dias - Conjunto de teste.



Os resultados indicam que o modelo apresenta um bom desempenho em previsões de curto prazo, como mostra o gráfico com 1 dia de antecedência. Nesse caso, os picos de vazão são bem representados, tanto em relação ao tempo de ocorrência quanto à sua intensidade. Quando o horizonte de previsão é ampliado para 7 dias, nota-se uma diminuição na performance do modelo, com pequenos atrasos e subestimações nos picos. Ainda assim, observa-se uma boa convergência visual entre os valores reais e previstos, especialmente nos períodos de seca, em que a variação da vazão é mais suave.

As Figuras 4 e 5 apresentam, de outra maneira, como os dados previstos e os observados se relacionam, para as previsões de 1 e 7 dias, respectivamente. O ideal seria que os valores ficassem próximos da linha vermelha (reta 1:1), indicando que os resultados convergem com os dados de entrada.

Figura 4 - Valores reais e previsto – 1 dia - Conjunto de teste.

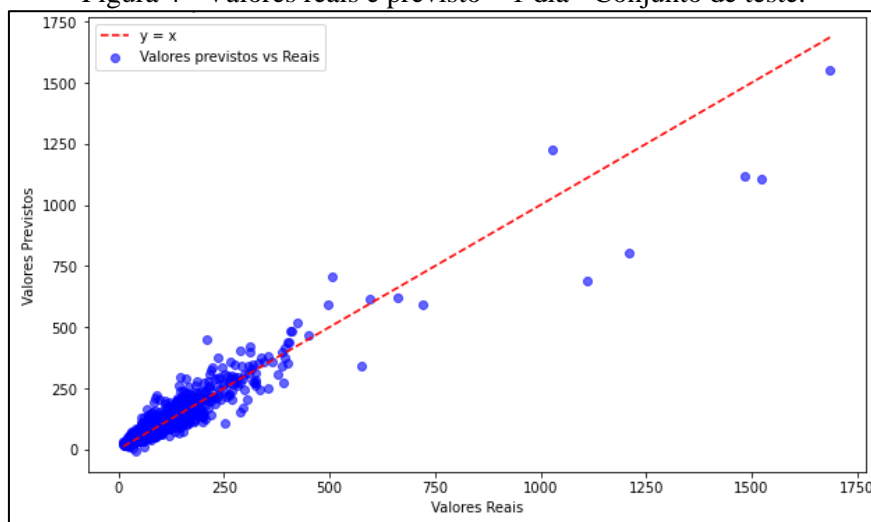
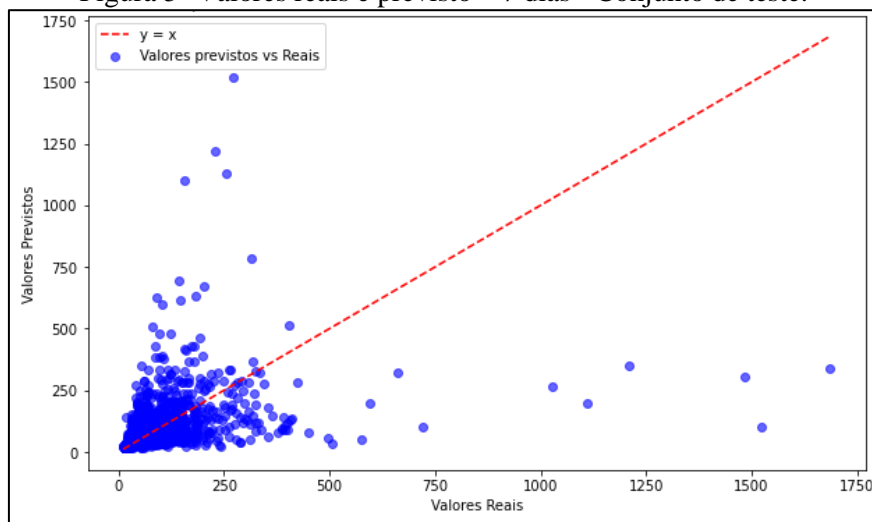


Figura 5- Valores reais e previsto – 7 dias - Conjunto de teste.



Os gráficos apresentados reforçam as diferenças no desempenho do modelo entre os horizontes de 1 e 7 dias. No caso da previsão com 1 dia, observa-se uma boa concentração dos pontos ao longo da linha de referência 1:1, o que indica uma forte correlação entre os valores previstos e os reais, especialmente para vazões mais baixas e moderadas. Isto sugere que o modelo consegue aprender e representar adequadamente a dinâmica de curto prazo. Já no gráfico com horizonte de 7 dias, há uma maior dispersão dos pontos, afastamento em relação à linha $y = x$, principalmente para valores elevados de vazão, que tendem a ser subestimados pelo modelo. Essa maior dispersão mostra que o modelo perde precisão nas previsões com maior antecedência e tem mais dificuldade para representar corretamente os eventos de maior vazão. Mesmo que a tendência geral seja bem capturada nos dois casos, o desempenho do modelo é visivelmente melhor em previsões de curto prazo.

Já as Figura 6 e 7 apresentam a distribuição dos resíduos de acordo com a vazão, para as previsões de 1 e 7 dias, respectivamente. Como já mencionado anteriormente, os resíduos são as diferenças entre os valores observados e previsto, assim sendo, quando mais próximo de zero, melhor a precisão dos resultados.

Figura 6 – Resíduos – 1 dia – Conjunto de teste.

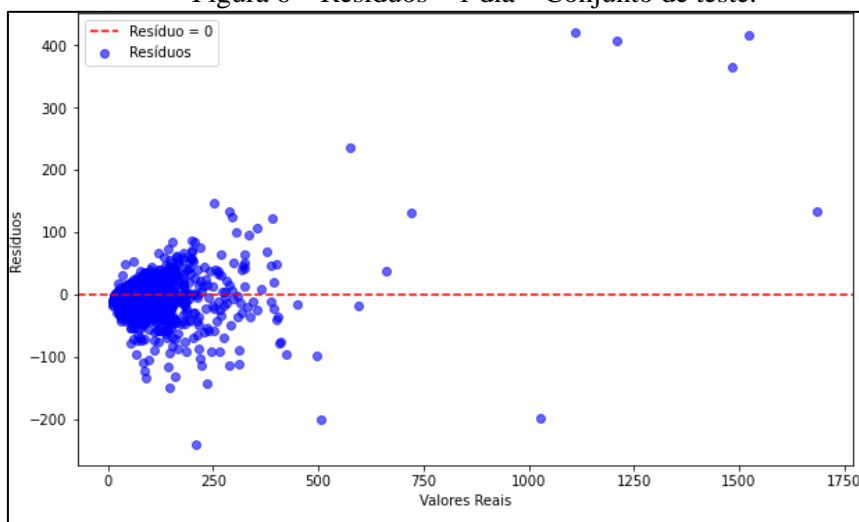
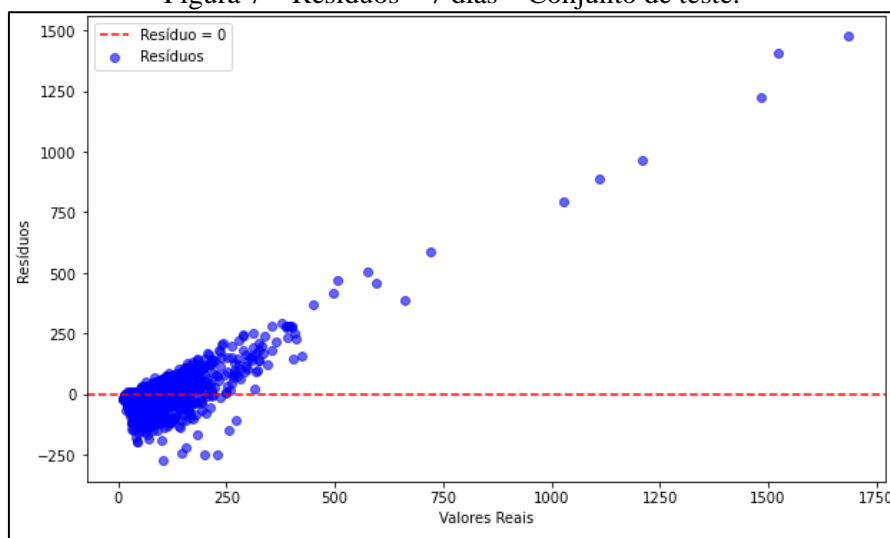


Figura 7 – Resíduos – 7 dias – Conjunto de teste.



Conforme os outros gráficos já apresentados, observa-se que, em ambas as previsões, o modelo se ajusta melhor a vazões menores. No entanto, a partir destes gráficos de resíduos há uma diferença significativa na magnitude dos erros, enquanto os resíduos da previsão com 1 dia variam aproximadamente entre -200 e 400, os da previsão com 7 dias atingem valores de -250 até 1500. Na previsão com 1 dia de antecedência, os pontos estão mais concentrados ao redor da linha de referência (resíduo = 0), o que indica baixa dispersão e ausência de viés sistemático. Já para o horizonte de 7 dias, a dispersão é bem maior, especialmente em dias de elevada vazão, revelando uma tendência de subestimação e perda de precisão. Esses resultados reforçam que, embora o modelo consiga captar a tendência geral do comportamento hidrológico, seu desempenho é muito mais confiável em horizontes curtos, necessitando de novas estratégias (e.g., acoplamento de modelos de previsão meteorológica) para aprimorar os resultados de 7 dias.

CONSIDERAÇÕES FINAIS

O presente estudo avaliou o desempenho de uma rede neural do tipo MLP na previsão de vazões em uma sub-bacia da bacia do Rio Piracicaba, em Minas Gerais. A análise envolveu dois horizontes distintos de previsão, de 1 e 7 dias, permitindo avaliar a robustez do modelo frente a diferentes escalas temporais. Os resultados mostraram que o modelo obteve melhor desempenho nas previsões de curto prazo, especialmente para vazões baixas e moderadas, com valores satisfatórios das métricas estatísticas (MAE, RMSE, NSE e PBIAS) e menor dispersão nos gráficos de dispersão e resíduos.

Por outro lado, a previsão com 7 dias de antecedência apresentou perda significativa de desempenho, evidenciada por maiores erros, dispersão mais acentuada e subestimação de eventos extremos. As métricas associadas a esse horizonte confirmaram essa limitação, com destaque para a queda do coeficiente NSE e o aumento considerável do RMSE. Esses resultados indicam que, embora o modelo capte adequadamente a tendência geral da série, sua capacidade preditiva é mais confiável em horizontes curtos.

Adicionalmente, destaca-se que a implementação do modelo, bem como a análise dos dados, foi conduzida integralmente em linguagem Python, utilizando as plataformas Anaconda e Jupyter Notebook.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo financiamento à participação no simpósio, sob o processo nº PCE-00429-25.

À Universidade Federal de Minas Gerais (UFMG), pela infraestrutura acadêmica e suporte institucional oferecidos para a realização deste estudo.

Ao grupo de pesquisa Hydro-Uai, pelo apoio técnico-científico e pelas contribuições ao longo do desenvolvimento desta pesquisa.

REFERÊNCIAS

ANA - AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO. Portal HidroWeb. Disponível em: <<https://www.snirh.gov.br/hidroweb/apresentacao>>.

ANEEL - AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. Sistema de Informações Georreferenciadas do Setor Elétrico (SIGEL). Disponível em: <<https://sigel.aneel.gov.br/portal/home/item.html?id=947a10caf45249faacd8c45ac74573c7>>.

BOUIX, C. P. S. Modelagem de redes neurais artificiais MLP para previsão de vazões na bacia do rio Miranda afluente do Pantanal. Piracicaba: Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, 2024. Dissertação de Mestrado. Disponível em: <<https://doi.org/10.11606/D.11.2024.tde-10052024-112545>>.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Sistema Brasileiro de Classificação de Solos. Ministério da Agricultura, Pecuária e Abastecimento. 5ª Edição. Brasília, 2018. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1094003/sistema-brasileiro-de-classificacao-de-solos>>.

GARCÍA, S., LUENGO, J., & HERRERA, F. Data Preprocessing in Data Mining. Springer, 2015.

GONÇALVES, A. R. Redes neurais artificiais. Campinas: Universidade Estadual de Campinas, 2020.

LIPPMANN, R. An introduction to computing with neural nets. IEEE ASSP Magazine, v. 4, n. 2, p. 4–22, 1987.

MAPBIOMAS. Projeto MapBiomas - Coleção 9 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. Disponível em: <<https://plataforma.brasil.mapbiomas.org/>>.

YU, Q.; TOLSON, B. A.; SHEN, H.; HAN, M.; MAI, J.; LIN, J. Enhancing Long Short-Term Memory (LSTM)-Based Streamflow Prediction with a Spatially Distributed Approach. Hydrology and Earth System Sciences, v. 28, p. 2107–2122, 2024. Disponível em: <<https://doi.org/10.5194/hess-28-2107-2024>>.