

INTEGRAÇÃO DE PSO E REDES NEURAIS MLP PARA MODELAGEM HIDROLOGICA E PREVISÃO DE VAZÕES EM MICROBACIA DO RIO PIRANGA (MG)

Marina Marcela de Paula Kolanski¹; Taís Fonte Boa de Campos Maia²; André Ferreira Rodrigues³; Bruno Melo Brentan⁴ & Gustavo Meirelles Lima⁵

Palavras-Chave – PSO, MLP, Previsão de vazões.

INTRODUÇÃO

A intensificação de eventos climáticos extremos tem impactado a gestão de recursos hídricos, exigindo ferramentas mais robustas para previsão de vazões em diferentes cenários. Modelos híbridos que combinam inteligência artificial e técnicas de otimização têm se mostrado promissores frente à complexidade e não linearidade dos processos hidrológicos. Este estudo propõe a integração entre Redes Neurais Artificiais do tipo Perceptron de Múltiplas Camadas (MLP) e o algoritmo de Otimização por Enxame de Partículas (PSO) para melhorar a acurácia da previsão de vazões na microbacia do Rio Piranga (MG), localizada na bacia do Rio Doce.

METODOLOGIA

A pesquisa foi conduzida na microbacia do Rio Piranga, onde foram selecionadas estações fluviométricas, pluviométricas e meteorológicas com séries temporais consistentes desde 1976. As séries com até 5% de falhas foram tratadas via imputação de dados, sendo testados três métodos: média, interpolação linear e k-vizinhos mais próximos (KNN), com este último se mostrando o mais eficiente.

Após o pré-processamento, as redes MLP foram treinadas com variáveis climáticas (como precipitação e temperatura) para previsão de vazões nos horizontes de t+1 e t+7 dias. A arquitetura da rede incluiu camadas ocultas com diferentes números de neurônios e funções de ativação (ReLU ou sigmoide), sendo o treinamento feito com o otimizador Adam e função de perda baseada no erro quadrático médio (MSE).

Paralelamente, foi aplicada a Otimização por Enxame de Partículas (PSO) para calibrar os parâmetros hidrológicos de um modelo chuva-vazão conceitual (γ , α , m , ks e v), inicialmente estimados por Monte Carlo. A PSO utilizou 50 partículas em 100 iterações, ajustando os parâmetros com base na minimização do erro entre vazões simuladas e observadas.

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

² SMARH - Universidade Federal de Minas Gerais (UFMG), Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG. 31270-901. Taisfb10@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

A vazão simulada pela PSO foi então incorporada como uma variável de entrada adicional ao modelo MLP, criando uma abordagem híbrida que alia informações físicas e estatísticas. Por fim, foi implementado um ajuste na função de perda do modelo MLP, atribuindo pesos maiores aos erros em eventos extremos — definidos como valores abaixo do percentil 10% (secas) e acima do percentil 90% (picos) — para intensificar o aprendizado em situações críticas.

RESULTADOS

A MLP isolada mostrou bom desempenho para t+1, mas dificuldades em prever picos e estiagens em t+7. A incorporação da vazão simulada via PSO como entrada adicional na MLP resultou em melhorias no desempenho preditivo, principalmente na representação de padrões sazonais. A posterior alteração da função de perda focando eventos extremos gerou ganhos significativos na aderência das previsões para esses casos, conforme evidenciado nos gráficos de comparação entre vazões observadas e previstas.

CONCLUSÕES

A abordagem híbrida PSO-MLP apresentou desempenho superior à aplicação isolada de redes neurais, especialmente na previsão de eventos hidrológicos extremos. A calibragem dos parâmetros hidrológicos com PSO, seguida da integração com a MLP, permitiu maior robustez ao modelo, tornando-o mais sensível às variações críticas. A metodologia proposta pode ser aplicada em outras bacias e servir como apoio à tomada de decisão em contextos de risco hídrico.

REFERÊNCIAS

- STEPHENSON, D. B. (2008). “*The role of extreme events in the validation and evaluation of climate models*”. Quarterly Journal of the Royal Meteorological Society, 134(632), 1743–1763. <https://doi.org/10.1002/qj.284>.
- HOCHREITER, S., & SCHMIDHUBER, J. (1997). “*Long short-term memory*”. Neural Computation, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- KHOSRAVI, A., EBRAHIM, P., & MARZBAND, M. (2018). “*Prediction of extreme events using machine learning techniques*”. Engineering Applications of Artificial Intelligence, 73, 119-135. <https://doi.org/10.1016/j.engappai.2018.05.010>.
- VAN HOUDT, R., MOSQUERA, F., & NÁPOLES, D. (2020). “*Hybridizing particle swarm optimization and deep learning for forecasting extreme hydrological events*”. Environmental Modelling & Software, 131, 104739. <https://doi.org/10.1016/j.envsoft.2020.104739>.
- FILHO, A. S. (2021). “*A study of machine learning techniques and Monte Carlo simulations in predicting extreme hydrological events*”. Journal of Hydrology, 601, 126591. <https://doi.org/10.1016/j.jhydrol.2021.126591>.

AGRADECIMENTOS

À Fapemig pelo financiamento à participação no simpósio, sob processo n° PCE-00429-25. À Universidade Federal de Minas Gerais (UFMG) pelo apoio institucional e pela infraestrutura disponibilizada para a realização deste artigo. Ao Grupo de Pesquisa em Recursos Hídricos e Inteligência Artificial (Hydro-UAI) pelas valiosas contribuições técnicas, científicas e pela troca de conhecimentos ao longo do desenvolvimento da pesquisa.