

REDES DE MONITORAMENTO RESILIENTES: COMO PRIORIZAR ESTAÇÕES HIDROMETEOROLÓGICAS COM IA EXPLICÁVEL?

Pedro Henrique Bernardes Solha¹; Rodrigo Gomes Bezerra Perdigão²; Bruno Melo Brentan³;

Andrea Menapace⁴ & André Ferreira Rodrigues⁵

Palavras-Chave – Previsão de cheias, IA explicável, Sistemas de Alerta de Inundação.

INTRODUÇÃO

O risco de inundações tem aumentado em escala global devido às mudanças climáticas e à urbanização acelerada (Miller & Hutchins, 2017; IPCC, 2021). Eventos extremos de precipitação mais frequentes, combinados com a crescente impermeabilização do solo, tornam a implementação de sistema de alerta de inundação eficazes uma prioridade. Assim, espera-se que esses sistemas sejam concebidos a partir de abordagens rápidas, eficazes e de baixo custo, como por exemplo combinando o aprendizado de máquina (ML) com princípios hidrológicos para lidar a complexidade dos processos físicos desses eventos (Schanze, 2006; Plate, 2002).

O presente trabalho apresenta uma estrutura de priorização de rede de monitoramento, baseada em três etapas: (i) modelagem preditiva com redes neurais Perceptron Multicamadas (MLP), (ii) uso de algoritmo de deterioração de séries temporais para simular falhas de sensores, e (iii) aplicação de inteligência artificial explicável (XAI) para interpretar e validar resultados. A área de estudo é a Bacia do Rio Piracicaba (SP), monitorada por uma rede de 16 estações pluviométricas e fluviométricas.

METODOLOGIA

A modelagem foi realizada a partir da estrutura de rede neural MLP, treinada com dados de 2016 a 2022 (resolução de 10 minutos), para horizontes de previsão de 3 e 24 horas (WMO, 2015), para previsão de nível de água na cidade de Piracicaba (SP). A rede foi alimentada com dados históricos de chuva e nível das estações da rede, e os resultados avaliados com base na eficiência de Nash-Sutcliffe (Nash & Sutcliffe, 1970). Os hiperparâmetros foram ajustados por grid search, e

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

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

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

4) Institute for Renewable Energy, Eurac Research, Viale Druso Drususallee, 1, 39100 Bolzano, Autonome Provinz Bozen - Südtirol, Itália. andrea.menapace@eurac.edu

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

utilizou-se o otimizador Adam (Kingma & Ba, 2014) com parada antecipada e regularização por dropout.

Para avaliar a resiliência do sistema frente à falhas dos sensores, desenvolveu-se um algoritmo de deterioração de séries temporais, que substitui partes dos dados por zeros, simulando falhas nos sensores. As deteriorações foram aplicadas separadamente por estação e sazonalmente (estação chuvosa, seca ou ano todo). Complementarmente, a interpretabilidade do modelo foi explorada com a técnica SHAP (SHapley Additive exPlanations), proposta por Lundberg e Lee (2017), que quantifica a contribuição de cada variável de entrada (estações) para a previsão. Essa abordagem permitiu identificar estações críticas para diferentes horizontes de previsão e comparar os resultados com os obtidos nos cenários de deterioração.

RESULTADOS

A acurácia das previsões caiu com a deterioração dos dados, evidenciando as estações críticas para cada horizonte de previsão. Para previsões de curto prazo, a estação 713 foi a mais relevante por estar próxima ao ponto de interesse, enquanto para previsões de longo prazo passam a depender também de estações a montante, como a 55, resultado que se alinha com o conceito de tempos de propagação das cheias na bacia.

A análise SHAP confirmou essas observações ao indicar as mesmas estações como influentes para a previsão, indicando que as abordagens de explicabilidade e deterioração são coerentes entre si. Um modelo otimizado com apenas as cinco estações mais importantes se mostrou mais sensível à perda de informações, evidenciando a importância de uma rede diversificada para garantir resiliência em condições reais.

CONCLUSÕES

Este estudo apresenta como a integração entre aprendizado de máquina, análise de robustez via deterioração de dados e inteligência artificial explicável pode auxiliar a concepção de sistemas de alerta de inundação mais eficientes, transparentes e hidrológicamente coerentes. A análise conjunta dos impactos da deterioração e dos valores SHAP permitiu identificar os sensores mais importantes para as previsões. Identificou-se que, embora seja possível reduzir a rede de monitoramento mantendo a performance do modelo, essa simplificação compromete a resiliência do sistema diante de falhas ou perda de dados. A estrutura proposta oferece suporte à tomada de decisão para otimização de redes de monitoramento, indicando quais estações devem ser priorizadas em manutenção e investimentos.

REFERÊNCIAS

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). Climate Change 2021: The Physical Science Basis: Contribution of Working Group I to the Sixth Assessment Report of the IPCC. Cambridge: Cambridge University Press, 2021.

KINGMA, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980.

LUNDBERG, S. M.; LEE, S. A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems, v. 30, p. 4765–4774, 2017.

MILLER, J. D.; HUTCHINS, M. The impacts of urbanization and climate change on urban flooding and urban water quality: A review of the evidence concerning the United Kingdom. Journal of Hydrology: Regional Studies, v. 12, p. 345–362, ago. 2017.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I — A discussion of principles. Journal of Hydrology, v. 10, n. 3, p. 282–290, 1970.

PLATE, E. J. Flood risk and flood management. Journal of Hydrology, [S.l.], v. 267, p. 2–11, 2002. DOI: 10.1016/S0022-1694(02)00135-X.

SCHANZE, J. Flood risk management – A basic framework. In: SCHANZE, J.; ZEMAN, E.; MARSCHAL, J. (org.). Flood risk management: Hazards, vulnerability and mitigation measures. Dordrecht: Springer, 2006. p. 1–20.

WORLD METEOROLOGICAL ORGANIZATION (WMO). Guidelines on multi-hazard impact-based forecast and warning services. Geneva: WMO, 2015.

AGRADECIMENTOS

Agradeço à Fapemig pelo financiamento à participação no congresso sob processo número PCE-00429-25.