

MODELOS HIDROLÓGICOS BASEADOS EM APRENDIZADO DE MÁQUINA PARA INUNDAÇÕES REPENTINAS: A DEMANDA POR UMA REVISÃO SISTEMÁTICA DA LITERATURA

Leonardo B. L. Santos¹ & Elton V. Escobar-Silva²

Palavras-Chave – Inteligência artificial, Aprendizado de máquina, Inundações repentinas, Escoamento superficial, Desastres.

INTRODUÇÃO

As inundações representam uma fonte de ameaça tanto para os países desenvolvidos como para os países em desenvolvimento. Cerca de 44% dos desastres em todo o mundo estão associados a inundações, e os diferentes tipos de inundações são responsáveis por 31% das perdas económicas (WMO, 2021). As inundações repentinas são um dos tipos mais comuns de desastres naturais em todo o mundo (Gourley *et al.*, 2013; Georgakakos *et al.*, 2022). Elas são definidas como um rápido aumento do nível da água (0-12h), muitas vezes desencadeado naturalmente por fortes chuvas (Bucherie *et al.*, 2022), derretimento rápido da neve (Yan *et al.*, 2023), ou induzido por rupturas de barragens e diques (Yang *et al.*, 2020).

Neste contexto, a modelagem de inundações repentinas enfrenta muitos desafios, uma vez que os modelos hidrológicos físicos são inadequados para uma pequena escala espaço-temporal (Clark *et al.*, 2017). Com a maior disponibilidade de dados hidrológicos observados, uma abordagem alternativa é utilizar técnicas de Aprendizado de Máquina (do inglês *Machine Learning* – ML), uma subárea da inteligência artificial (do inglês *artificial intelligence*). Em comparação com os métodos estatísticos tradicionais, os modelos de ML podem realizar previsões com melhor precisão (Makridakis *et al.*, 2021). Porém, apesar de uma vasta variedade de métodos de ML, existem algumas lacunas sobre a utilização destas técnicas na modelagem de inundações. Como consequência, existe uma demanda por uma Revisão Sistemática da Literatura (do inglês *Systematic Literature Review* – SLR), no cenário de pesquisa, para aprimorar a compreensão das aplicações de ML para modelagem de inundações repentinas. Assim, este trabalho apresenta os pontos principais da SLR realizada por Santos *et al.* (2024).

METODOLOGIA

Começando com mais de 1.217 artigos publicados até janeiro de 2024 e indexados nas bases de dados Web of Science, SCOPUS/Elsevier, Springer/Nature ou Wiley, Santos *et al.* (2024) selecionaram 53 trabalhos para análise detalhada, seguindo as diretrizes dos Principais Itens para Relatar Revisões Sistemáticas e Meta-análises 2000 (do inglês *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* – PRISMA 2000) (Page *et al.*, 2021). Os critérios de inclusão/exclusão removeram revisões, retratações e artigos que não estavam no escopo desta RSL e incluíram apenas artigos com resolução temporal inferior a 12 horas. Dados sobre horizonte de previsão, área, método e informações foram extraídos de cada estudo para identificar quais técnicas de ML e designs de modelos foram aplicados à previsão de inundações repentinas.

1) Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden), leonardo.santos@cemaden.gov.br e santoslbi@gmail.com

2) Instituto Nacional de Pesquisas Espaciais (INPE), elton.silva@inpe.br e eltescobar@gmail.com

RESULTADOS

Constatou-se que houve um aumento notável em publicações investigando técnicas de ML para modelagem de inundações repentinas nos últimos anos. A maioria dos estudos concentra-se em regiões da China (36%) e dos Estados Unidos (11%). Do total de artigos selecionados, mais de 90% utilizaram como dados de entrada apenas uma ou uma combinação exclusiva das seguintes medidas: vazão, precipitação e nível de água (Santos *et al.*, 2024).

Desse conjunto, a combinação de vazão e precipitação aparece em quase metade dos artigos. Quase 60% dos estudos utilizam o método de memória de longo prazo (do inglês *long short-term memory* – LSTM). Um dos resultados mais surpreendentes desta análise é que nenhum método tem sempre um desempenho melhor do que qualquer outro. Infelizmente, menos de 10% dos artigos selecionados fornecem acesso aos seus dados (Santos *et al.*, 2024).

CONCLUSÕES

O uso de abordagens de ML na previsão de inundações é promissor. Porém, para converter esse potencial teórico em produtos e aplicações práticas e maximizar seus impactos, é necessário empreender um conjunto de ações que envolvam esforços coletivos. Neste sentido, Santos *et al.* (2024) recomendam sua integração de modelos de ML em sistemas de alerta precoce, desenvolvimento e divulgação de parâmetros de referência (*benchmarks*), publicação de estudos de caso bem-sucedidos e colaboração multidisciplinar.

REFERÊNCIAS

BUCHERIE, A.; WERNER, M.; VAN DEN HOMBERG, M.; TEMBO, S. (2022). *Flash flood warnings in context: combining local knowledge and large-scale hydro-meteorological patterns*. *Natural Hazards and Earth System Sciences* 22, 461–480. DOI 10.5194/nhess-22-461-2022.

CLARK, M. P.; BIERKENS, M. F. P.; SAMANIEGO, L., WOODS, R. A.; UIJLENHOET, R.; BENNETT, K. E.; PAUWELS, V. R. N.; CAI, X.; WOOD, A. W.; PETERS-LIDARD, C. D. (2017). *The evolution of process-based hydrologic models: historical challenges and the collective quest for physical realism*. *Hydrology and Earth System Sciences* 21, 3427–3440. DOI 10.5194/hess-21-3427-2017.

GEORGAKAKOS, K. P.; MODRICK, T. M.; SHAMIR, E.; CAMPBELL, R.; CHENG, Z.; JUBACH, R.; SPERFSLAGE, J. A.; SPENCER, C. R.; BANKS, R. (2022). *The flash flood guidance system implementation worldwide: A successful multidecadal research-to-operations effort*. *Bulletin of the American Meteorological Society* 103, E665 – E679. DOI 10.1175/BAMS-D-20-0241.1.

GOURLEY, J. J.; HONG, Y.; FLAMIG, Z. L.; ARTHUR, A.; CLARK, R.; CALIANNI, M.; RUIN, I.; ORTEL, T.; WIECZOREK, M. E.; KIRSTETTER, P. E.; CLARK, E.; KRAJEWSKI, W. F. (2013). *A unified flash flood database across the United States*. *Bulletin of the American Meteorological Society* 94, 799 – 805.

MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V. (2018). *Statistical and Machine Learning forecasting methods: Concerns and ways forward*. *PLoS one*, 13(3), e0194889.

PAGE, M. J.; MOHER, D.; BOSSUYT, P. M.; BOUTRON, I.; HOFFMANN, T. C.; MULROW, C. D.; SHAMSEER, L.; TETZLAFF, J. M.; AKL, E. A.; BRENNAN, S. E.; CHOU, R.; GLANVILLE, J.; GRIMSHAW, J. M.; HR'OBJARTSSON, A.; LALU, M. M.; LI, T.; LODER, E. W.; MAYO-WILSON, E.; MCDONALD, S.; MCGUINNESS, L. A.; STEWART, L. A.; THOMAS, J.; TRICCO,

A. C.; WELCH, V. A.; WHITING, P.; MCKENZIE, J. E. (2021). *Prisma 2020 explanation and elaboration: updated guidance and exemplars for reporting systematic reviews*. *BMJ* 372. DOI 10.1136/bmj.n160.

SANTOS, L. B. L.; SATOLO, L. F.; OYARZABAL, R. S.; ESCOBAR-SILVA, E. V.; DINIZ, M. M.; NEGRI, R. G.; LIMA, G. R. T.; STEPHANY, S.; SOARES, J. A. P.; DUQUE, J. S.; SARAIVA-FILHO, F. L.; BACELAR, L. (2024). *Machine Learning-based Hydrological Models for Flash Floods: A Systematic Literature Review*. DOI 10.31223/X5C699. **Pre-print**.

WMO – World Meteorological Organization. *Atlas of mortality and economic losses from weather, climate and water extremes (1970–2019)*. WMO-No. 12 ed. Geneva, Switzerland: World Meteorological Organization, 90 p. ISBN 9789263112675.

YAN, H.; SUN, N.; WIGMOSTA, M. S.; DUAN, Z.; GUTMANN, E. D.; KRUYT, B.; ARNOLD, J. R. (2023). *The role of snowmelt temporal pattern in flood estimation for a small snow-dominated basin in the Sierra Nevada*. *Water Resources Research* 59, e2023WR034496. DOI <https://doi.org/10.1029/2023WR034496>.

YAN, L.; CHEN, C.; HANG, T.; HU, Y. (2021). *A stream prediction model based on attention-LSTM*. *Earth Science Informatics* 14, 723–733. DOI 10.1007/s12145-021-00571-z.

AGRADECIMENTOS

Este estudo foi financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), projeto 446053/2023-6 e pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) projeto 2024/02748-7. Por fim, os autores desse trabalho agradecem a todos os autores do trabalho “*Machine Learning-based Hydrological Models for Flash Floods: A Systematic Literature Review*” (Santos *et al.*, 2024) pelo compartilhamento de informações e dados.