

USO DE REDES NEURAIIS PARA PREVISÃO DE INUNDAÇÃO EM BACIAS URBANAS NA ÚLTIMA DÉCADA: REVISÃO BIBLIOGRÁFICA

Guilherme Nascimento Avelino¹; Greicelene Jesus da Silva² & Maria Clara Fava³

RESUMO – Diante do avanço das mudanças climáticas e urbanização, se fazem necessárias ferramentas capazes de prevenir e mapear eventos de inundação. Tradicionalmente, essa análise é realizada por meio de modelos hidrodinâmicos, os quais apresentam alto custo computacional e tempo de processamento. Visando contornar isso, há crescente utilização de modelos orientados a dados, como redes neurais, capazes de gerar previsões precisas em tempos menores. Assim, esta revisão bibliográfica propõe compreender as arquiteturas que estão sendo utilizadas para a previsão de inundação em bacias urbanas. Após pesquisa nas bases de periódicos *SCOPUS* e *Web of Science*, 1.192 artigos foram filtrados em 110 relevantes dentro do tema, sendo feita a análise temporal e categorização dos modelos utilizados, além da discussão das dez pesquisas com maior impacto acadêmico. Assim, foi observado um crescimento nas publicações deste assunto ao longo do tempo, com a evolução de complexidade e vantagens específicas, ocorrendo um aumento expressivo no uso de redes neurais recorrentes, convolucionais, híbridas e outras abordagens, apresentando mudanças de paradigma na literatura. Porém, ainda há limitações comuns entre modelos, como a escassez de dados e dificuldade de generalização, sendo importante então investigações nesse sentido para tentar minimizar esses obstáculos, levando a diminuição dos desastres urbanos por inundações.

Palavras-Chave – Previsão de inundação, modelos substitutos, bacias urbanas.

ABSTRACT– In light of the advancement of climate change and urbanization, tools capable of preventing and mapping flood events are required. The traditional approach involves the use of hydrodynamic models, which are time-consuming and computationally expensive. To overcome this limitation, there has been a growing adoption of data-driven models, such as neural networks, capable of producing accurate forecasts in shorter time frames. Thus, this literature review aims to understand the architectures being used for flood prediction in urban catchments. After a search in SCOPUS and Web of Science databases, 1,192 articles were identified, with 110 selected as relevant. A temporal analysis and categorization of the employed models were conducted, as well as a discussion of the ten most academically impactful studies. The results indicate an increasing trend in publications over time, alongside the evolution of model complexity and specific advantages, with a significant rise in the use of recurrent, convolutional, hybrid neural networks and other approaches, indicating paradigm shifts in the literature. However, common limitations remain across models, such as data scarcity and difficulty in generalization, making further investigation essential to mitigate these obstacles, ultimately contributing to the reduction of urban flood disasters.

Key-words – Flood forecast, surrogate models, urban basins.

INTRODUÇÃO

¹) Universidade Federal de São Carlos - UFSCar, Rod. Washington Luís, km. 235, São Carlos, gnavelino@estudante.ufscar.br

²) Universidade Federal de São Carlos - UFSCar, Rod. Washington Luís, km. 235, São Carlos, gjsilva@ufscar.br

³) Universidade Federal de São Carlos - UFSCar, Rod. Washington Luís, km. 235, São Carlos, mcfava@ufscar.br

Com o avanço da urbanização, há uma expansão contínua de superfícies impermeáveis que reduz a capacidade de infiltração do solo e sobrecarrega os sistemas de drenagem. Com isso em vista, e, diante da intensificação das mudanças climáticas com cada vez mais eventos de inundações em cidades, é relevante o desenvolvimento de ferramentas que auxiliem na previsão e mapeamento dessas ocorrências (Rjeily *et al.*, 2017).

Tradicionalmente, a previsão de inundações e condições dos sistemas de drenagem urbana são realizados com auxílio de modelos hidrológicos e hidrodinâmicos, como o SWMM e o MIKE (Zhou *et al.*, 2023; Kim e Han, 2020). Embora esses modelos conseguiram apresentar representações detalhadas do escoamento superficial e do fluxo em redes de tubulações, sua aplicação enfrenta algumas limitações. A principal delas está no alto custo computacional, sendo necessário grandes quantidades de dados e calibrações, que resultam em tempos longos de processamento para as simulações, portanto dificultando seu uso em operações em tempo real ou de curto prazo (Berkhahn *et al.*, 2019).

Para contornar esses problemas, os modelos orientados a dados (*data-driven models*), especialmente os de redes neurais, vem ganhando espaço na literatura científica. Essas arquiteturas conseguem atuar como modelos substitutos (*surrogate*), sendo capazes de mapear as relações não-lineares entre variáveis estáticas e dinâmicas dentro do contexto hidrológico (Rjeily *et al.*, 2017). A grande vantagem desses modelos está na sua maior velocidade preditiva pós-treinamento, viabilizando que as estimativas sejam geradas em apenas alguns segundos, essencial, por exemplo, para sistemas de alerta precoce voltados para bacias urbanas. (Löwe *et al.*, 2021; Chang *et al.*, 2022).

Nesse sentido, o objetivo principal deste estudo de revisão é contextualizar as arquiteturas de rede neural que têm sido utilizadas ao longo da última década para a previsão de inundação em bacias urbanas.

METODOLOGIA

Realizou-se um levantamento bibliográfico em duas bases de dados, *SCOPUS* e *Web of Science*. Para a primeira, foi utilizada a pesquisa avançada de documentos, com descritores específicos: *TITLE-ABS-KEY ("neural network*" OR "artificial neural network*" OR "ANN*") AND TITLE-ABS-KEY ("flood prediction*" OR "flood forecast*" OR "flood model*" OR "nowcast*") AND TITLE-ABS-KEY ("urban area*" OR "urban basin*" OR "urban catchment*" OR "urban watershed*") AND PUBYEAR > 2015 AND PUBYEAR < 2027 AND (LIMIT-TO (DOCTYPE,"ar"))*. Esses descritores buscam nos campos título, resumo e palavras-chave, além de

delimitar apenas para artigos publicados nos anos de 2016 até 2026. Da mesma forma, foi utilizada essa busca na base de dados *Web of Science*, também limitando a pesquisa por artigos publicados nos últimos dez anos.

Sendo assim, foram encontrados 111 artigos pela *SCOPUS* e 1.163 pela *Web of Science*. Após a compilação desses artigos, foi realizada a remoção de 82 artigos duplicados, resultando num primeiro acervo de 1.192 artigos únicos. Em seguida, foi realizada uma filtragem inicial, com a leitura dos títulos e resumo (*abstract*) de todos, buscando remover aqueles que não se encontravam no escopo dessa revisão e selecionando apenas os que tratavam sobre redes neurais para a previsão de inundações em bacias urbanas.

A partir disso, foram delimitados 110 artigos potencialmente relevantes. Com base nesse conjunto, foi elaborada a Figura 1 que mostra o crescimento de publicações de artigos sobre o tema ao longo dos últimos anos.




Figura 1 – Distribuição temporal das publicações

Com esses 110 artigos potencialmente relevantes ainda em consideração, foram categorizados os modelos encontrados através da leitura de título e resumo (*abstract*). Para a definição dessas categorias, foi utilizada a principal característica de cada modelo.

Observa-se que as redes neurais são modelos computacionais compostos por neurônios artificiais em camadas e conectados por pesos ajustáveis. Durante o treinamento, esses parâmetros são calibrados iterativamente por algoritmos de otimização, minimizando o erro em relação aos dados de referência. A partir dessa estrutura básica, surgiram diferentes arquiteturas, adequando-se a tipos específicos de problemas e representações de dados.

Para identificação das categorias, as redes neurais denominadas “clássicas” foram determinadas pela característica principal da propagação unidirecional da informação, sem a

presença de mecanismos de realimentação, tendo como exemplo as redes neurais artificiais (ANN) e *Multilayer Perceptron* (MLP). Para as denominadas “recorrentes”, como por exemplo as redes neurais recorrentes (RNN) ou as *Long Short-Term Memory* (LSTM), tendo como definição possuírem conexões que permitem que as saídas sejam reutilizadas, relacionando dependências ao longo do tempo. Para as redes denominadas “convolucionais”, como as redes neurais convolucionais (CNN), são voltadas para a extração de padrões espaciais (*features*) por meio de operações de convolução, enquanto as denominadas híbridas são modelos que integram em sua arquitetura modelos físicos, outros tipos de redes neurais e até mesmo outras abordagens estatísticas, como as *Physics-Informed Neural Network* (PINN). Na categoria “outras”, foram incluídos modelos que não se enquadram nas categorias indicadas, como por exemplo as redes neurais em grafos (GNNs). Na Figura 2 é possível observar o gráfico das categorias ao longo do tempo, assim como os valores na Tabela 1.




Figura 2 – Categorias de arquiteturas

Tabela 1 – Categorias de arquiteturas

Ano	Clássicas	Recorrentes	Convolucionais	Híbridas	Outras
2016	2	0	0	0	0
2017	0	1	0	0	0
2018	2	1	0	0	0
2019	3	1	0	1	0
2020	7	4	0	0	0
2021	4	2	2	0	0
2022	7	9	1	4	0
2023	5	14	5	3	1
2024	7	6	8	3	3
2025	11	5	1	3	6
2026	2	6	8	2	6

Fonte: Autor

Posteriormente, foi realizada a análise da quantidade de citações, sendo através desta feita a seleção dos dez artigos mais citados, de forma a capturar as pesquisas com maior impacto acadêmico para discussão nesta revisão bibliográfica. O procedimento de metodologia está apresentado na Figura 3.




Figura 3 – Diagrama de metodologia

A partir desses dois conjuntos, foi feita a relação dos artigos potencialmente relevantes com os artigos selecionados após verificação da quantidade de citações, conforme pode ser visto na Figura 4.



Figura 4 – Diagrama de metodologia

Por fim, após a leitura dos dez artigos selecionados, foi desenvolvida a Tabela 2, relacionando os autores, categoria de arquitetura, tipo de problema, dados de entrada e relevância para o tema.

Tabela 2 – Modelagem de Inundações Urbanas por Redes Neurais

Autor	Arquitetura	Problema	Dados de Entrada	Relevância
Rjeily <i>et al.</i> (2017)	Recorrente (NARX)	Previsão de nível de água.	Séries temporais de chuva.	Substituiu a análise de toda a rede de drenagem para apenas os pontos críticos.
Jahangir <i>et al.</i> (2019)	Clássica (ANN)	Mapeamento de suscetibilidade de inundações.	Dados GIS, séries temporais de chuva.	Utilizou dados espaciais de GIS diretamente em um MLP.
Berkhahn <i>et al.</i> (2019)	Clássica (ANN)	Mapeamento de profundidade de inundação.	Séries temporais de chuva (sintético).	Utilizou um algoritmo de crescimento de topologia e método <i>ensemble</i> .
Zhou <i>et al.</i> (2019)	Híbrida (R-ANFIS)	Previsão de vazão.	Séries temporais de chuva e nível de água.	Utilizou um sistema <i>fuzzy</i> recorrente com algoritmo genético.
Kim & Han (2020)	Clássica (DNN)	Previsão de vazão.	Séries temporais de chuva.	Aplicou técnicas de aumento de dados (<i>data augmentation</i>) para lidar com escassez de dados.
Lei <i>et al.</i> (2021)	Convolutacional (CNN) e Recorrente (RNN)	Mapeamento de suscetibilidade de inundações.	Dados GIS.	Demonstrou o uso de redes neurais para previsão de inundação apenas com dados estáticos topográficos.
Löwe <i>et al.</i> (2021)	Convolutacional (U-Net)	Mapeamento de profundidade de inundação.	Dados GIS, séries temporais de chuva.	Utilizou uma combinação de variáveis espaciais para prever inundação em eventos de chuva não vistos antes.
Chang <i>et al.</i> (2022)	Híbrida (PCA-SOM-NARX)	Mapeamento de profundidade de inundação.	Séries temporais de chuva.	Abordou uma forma de comprimir e agrupar a dimensionalidade, diminuindo o tempo necessário para previsão.

Noor <i>et al.</i> (2022)	Clássica (ANN) e Recorrente (LSTM)	Previsão de nível de água.	Séries temporais de nível de água.	Aplicou mecanismos de atenção na rede neural.
Zhou <i>et al.</i> (2023)	Clássica (ANN), Recorrente (LSTM) e Convolutiva (CNN)	Previsão em tempo real de inundação.	Séries temporais de chuva.	Adaptou uma rede para entrada unidimensional e saída bidimensional, com aplicação de transferência de aprendizado.

Fonte: Autor

RESULTADOS E DISCUSSÃO

A partir da análise temporal, como visto na Figura 1, é possível perceber que é crescente a quantidade de publicações sobre o tema ao longo dos anos, com um volume 11,5 vezes maior em 2025 que em relação a 2016. Além disso, observando a Figura 2, pode-se notar uma transição progressiva de modelos estáticos para arquiteturas temporais, espaciais e híbridas. O principal motivo dessa evolução é a necessidade de desenvolver modelos substitutos (*surrogate models*) que consigam superar os desafios computacionais dos modelos hidrodinâmicos, como o grande custo de processamento e tempo para se obter as simulações (Rjeily *et al.*, 2017; Berkhahn *et al.*, 2019; Zhou *et al.*, 2023).

Conforme a Figura 2 ilustra, as arquiteturas clássicas ainda mantêm aplicações ao longo do período analisado, muitas vezes servindo como referência de comparação com as novas abordagens. Já entre 2022 e 2024 houve um aumento expressivo dos modelos recorrentes, com melhor capacidade de lidar com séries temporais. Ademais, a partir de 2022 se observa também o crescimento das abordagens híbridas. Até então, muitos modelos anteriores estavam focados exclusivamente na otimização de parâmetros na arquitetura de redes neurais, usualmente chamadas de caixas-pretas (*black box*), com baixa interpretabilidade dos resultados. Portanto, abordagens que integram a parte física dos processos hidrodinâmicos surgem dentro dessa categoria, visando aumentar a plausibilidade física das previsões.

A partir de 2024 há um grande aumento no uso de redes convolucionais, indicando avanços na aplicação para problemas espaciais. No primeiro trimestre de 2026 também houve a passagem da categoria mais utilizada para as convolucionais, superando as recorrentes e indicando o surgimento de uma nova tendência e mudança de paradigma nas abordagens do tema deste estudo. A seguir, as arquiteturas encontradas nos dez artigos mais relevantes são discutidas.

A literatura indica que as arquiteturas baseadas em alimentação direta (*feed-forward*) são utilizadas principalmente para o mapeamento de suscetibilidade de inundações e previsão de vazão. Esses modelos dependem tipicamente de uma combinação de variáveis, como propriedades do solo,

para extrair pesos matemáticos e estabelecer relações não-lineares (Jahangir *et al.*, 2019; Lei *et al.*, 2021).

A principal vantagem nesse tipo de utilização é a maior velocidade de processamento após seu treinamento, quando comparado com os modelos hidrodinâmicos. Porém, uma das limitações que ocorrem é o sobreajuste (*overfitting*) e a dificuldade de lidar com variáveis dinâmicas que dependem de relações temporais. Ainda assim, também é comum a escassez de dados reais de inundação urbana, restringindo o funcionamento dessas arquiteturas. Para lidar com isso, abordagens recentes fazem o uso de métodos de *ensemble*, realizando a média de várias previsões de um modelo de forma a suavizar as oscilações preditivas (Berkhahn *et al.*, 2019), bem como técnicas de aumento de dados (*data augmentation*) que injetam ruído estatísticos em séries temporais de chuva para enriquecer os dados de treinamento sem a necessidade de se obter novos eventos observados (Kim e Han, 2020).

Sabendo que a propagação de enchentes é um processo dinâmico, em que o estado atual depende dos estados passados, a literatura analisada passou a migrar para modelos temporais com mecanismos de recorrência. Redes como a *Nonlinear Autoregressive with Exogenous Inputs* (NARX), e RNNs utilizam as próprias saídas como entradas no sistema, podendo assim capturar as mudanças hidrológicas ao longo dos eventos de chuva, sendo eficazes para prever o nível d'água em pontos críticos a partir de séries temporais (Rjeily *et al.*, 2017).

Da mesma forma, modelos baseados em *Long Short-Term Memory* (LSTM) estão se consolidando por sua capacidade superior de manter informações de longo prazo através de mecanismos de memória (*gates*), demonstrando competência em aprender dependências temporais, superando modelos clássicos e reduzindo o efeito de atraso (*time-lag*) em previsões de múltiplos passos à frente (*multi-step ahead*) (Noor *et al.*, 2022; Zhou *et al.*, 2019). Algumas metodologias, como no caso de Zhou *et al.* (2023) buscam modificar a arquitetura unidimensional das LSTMs para receber hietogramas de precipitação e gerar mapas contínuos de inundação a partir deles, demonstrando que é possível adaptar os modelos temporais para espaço-temporais.

Ainda assim, quando é necessário a compreensão do espaço urbano, algo que os modelos recorrentes possuem limitações (Lei *et al.*, 2021), há um aumento do uso de redes neurais convolucionais (CNNs) para a extração de características espaciais estáticas a partir de dados matriciais (*raster*), sem ser necessário ponderar e selecionar manualmente as variáveis geográficas. Como exemplo, há a adaptação de modelos usados em segmentação de imagens (U-Net) para a geração de mapas contínuos de profundidade de água (Löwe *et al.*, 2021).

A literatura mostra também que, por exemplo, segundo *Chang et al.* (2022), é possível utilizar métodos híbridos para superar limitações. No caso do mesmo, foi possível prever simultaneamente milhares de células espaciais em múltiplos passos de tempo ao integrar a análise de componentes principais (PCA) e mapas auto-organizáveis (SOM) com redes recorrentes, reduzindo a dimensionalidade dos dados e posteriormente recompondo eles em mapas de inundação. Similarmente, integrações de sistemas *fuzzy* com algoritmos genéticos podem ser aplicados para evitar que os modelos fiquem presos em mínimos locais em previsões de longo prazo (*Zhou et al.*, 2019).

Uma das limitações comum entre todas as arquiteturas, dentro do tema em estudo, é que os modelos orientados a dados (*data-driven models*) se tornam especializados apenas na bacia hidrográfica com os dados que foram utilizados em seu treinamento, dependendo de bases de dados sintéticos geradas por modelos hidrodinâmicos para validação das previsões. Na literatura uma das formas de lidar com isso foi a aplicação de mecanismos de atenção, que permitem que a rede ajuste dinamicamente os pesos para os conjuntos de dados mais relevantes (*Noor et al.*, 2022), também há a exploração de técnicas de transferência de aprendizado (*transfer learning*) permitindo realizar a previsão em áreas não antes observadas pela rede sem a necessidade de treinar ela novamente, apenas realizando o ajuste fino (*fine-tuning*) (*Zhou et al.*, 2023).

CONCLUSÃO

A previsão de inundações em áreas urbanas é um tópico fundamental para lidar com desastres e proteção das populações frente ao maior número de eventos climáticos extremos. Com isso em mente, essa revisão buscou sistematizar as soluções em redes neurais para previsão desses eventos que vêm sendo exploradas na última década. A partir do levantamento inicial com 1.192 artigos, foram selecionados 110 após a filtragem inicial, com os dez de maior relevância acadêmica integrados na discussão. Sendo assim, foi possível observar uma evolução do número de publicações e também de complexidade dos modelos adotados, com a literatura transitando de arquiteturas clássicas (ANNs, MLPs) para redes recorrentes (RNNs, LSTMs), convolucionais (CNNs) e modelos híbridos ou com o uso de métodos estatísticos para o aumento de dados, mecanismos de atenção e outras abordagens.

Isso demonstra a busca por alternativas que consigam superar as limitações dos modelos hidrodinâmicos tradicionais, com a recente adoção majoritária de arquiteturas que capturem tendências espaço-temporais. Essa revisão contribui na organização dos modelos de redes neurais sendo empregados, assim como nos limites que ainda são encontrados, como a dependência de

dados sintéticos para validação e a dificuldade de generalização. Para superar esses desafios, é necessário que pesquisas futuras investiguem o aprimoramento das formas de lidar com escassez de dados observados e, principalmente, no uso de transferência de aprendizado (*transfer learning*).

REFERÊNCIAS

- BERKHAHN, S.; FUCHS, L.; NEUWEILER, I. (2019). “*An ensemble neural network model for real-time prediction of urban floods*”. Journal Of Hydrology 575, pp. 743-754.
- CHANG, L.; LIOU, J.; CHANG, F. (2022). “*Spatial-temporal flood inundation nowcasts by fusing machine learning methods and principal component analysis*”. Journal Of Hydrology 612, pp. 128086.
- JAHANGIR, M.H.; REINEH, S.M.M.; ABOLGHASEMI, M. (2019). “*Spatial predication of flood zonation mapping in Kan River Basin, Iran, using artificial neural network algorithm*”. Weather And Climate Extremes 25, pp. 100215.
- KIM, H.I.; HAN, K.Y. (2020). “*Urban Flood Prediction Using Deep Neural Network with Data Augmentation*”. Water, v. 12(3), pp. 899.
- LEI, X.; CHEN, W.; PANAH, M.; FALAH, F.; RAHMATI, O.; UUEMAA, E.; KALANTARI, Z.; FERREIRA, C.S.S.; REZAIE, F.; TIEFENBACHER, J.P. (2021). “*Urban flood modeling using deep-learning approaches in Seoul, South Korea*”. Journal Of Hydrology 601, pp. 126684.
- LÖWE, R.; BÖHM, J.; JENSEN, D.G.; LEANDRO, J.; RASMUSSEN, S.H. (2021). “*U-FLOOD – Topographic deep learning for predicting urban pluvial flood water depth*”. Journal Of Hydrology 603, pp. 126898.
- NOOR, F.; HAQ, S.; RAKIB, M.; AHMED, T.; JAMAL, Z.; SIAM, Z.S.; HASAN, R.T.; ADNAN, M.S.G.; DEWAN, A.; RAHMAN, R.M. (2022). “*Water Level Forecasting Using Spatiotemporal Attention-Based Long Short-Term Memory Network*”. Water 14(4), pp. 612.
- RJEILY, Y.A.; ABBAS, O.; SADEK, M.; SHAHROUR, I.; CHEHADE, F.H. (2017). “*Flood forecasting within urban drainage systems using NARX neural network*”. Water Science And Technology 76(9), pp. 2401-2412.
- ZHOU, Q.; TENG, S.; SITU, Z.; LIAO, X.; FENG, J.; CHEN, G.; ZHANG, J.; LU, Z. (2023). “*A deep-learning-technique-based data-driven model for accurate and rapid flood predictions in temporal and spatial dimensions*”. Hydrology And Earth System Sciences 27(9), pp. 1791-1808.
- ZHOU, Y.; GUO, S.; CHANG, F. (2019). “*Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts*”. Journal Of Hydrology 570, pp. 343-355.