

Avaliação da aplicabilidade de bases físicas em modelo LSTM para Sistemas de Previsão de Cheias: Estudo de Caso da Bacia do Rio Piracicaba

Rodrigo Perdigão Gomes Bezerra¹; Pedro Henrique Bernardes Solha¹; Bruno Melo Brentan¹;

Julian Cardoso Eleutério¹; André Ferreira Rodrigues¹

Abstract:

Flood forecasting remains a critical challenge in water resources engineering, particularly amid the increasing frequency and intensity of extreme hydrological events. Recurrent neural networks, such as Long Short-Term Memory (LSTM) models, have shown significant promise for streamflow prediction due to their ability to capture nonlinear and temporal dependencies. However, the integration of physically meaningful hydrological knowledge into such data-driven models remains underexplored. This study investigates the incorporation of classical hydrological concepts—specifically, hydrograph translation time between upstream and downstream gauges—as a guiding parameter for input data selection in LSTM-based forecasting models. The central hypothesis is that using flood wave travel time to define the past input window reduces redundant information and enhances model performance. The methodology is applied to the Piracicaba River basin (Minas Gerais, Brazil), combining hydrological sensitivity analysis with computational experiments. Results indicate that this physically informed strategy improves predictive skill and hydrological consistency, contributing to the development of more robust, interpretable flood forecasting systems.

Resumo:

A previsão de cheias permanece como um desafio relevante na engenharia de recursos hídricos, especialmente diante do aumento na frequência e intensidade de eventos extremos. Modelos baseados em redes neurais recorrentes, como o Long Short-Term Memory (LSTM), têm demonstrado grande potencial para a previsão de vazões por sua capacidade de capturar dependências não lineares e temporais. No entanto, a incorporação de conhecimento hidrológico explícito nesses modelos ainda é limitada. Este estudo propõe o uso do tempo de translado dos hidrogramas entre estações a montante e jusante como parâmetro orientador para a seleção da janela de dados passados utilizada como entrada no modelo LSTM. A hipótese central é que essa abordagem hidrológicamente embasada permite reduzir a inserção de informações redundantes e potencializar a capacidade preditiva do modelo. A metodologia é aplicada à bacia do rio Piracicaba (MG), combinando análise de sensibilidade hidrológica e experimentos computacionais. Os resultados apontam ganhos em desempenho preditivo e coerência hidrológica, reforçando o potencial de modelos mais robustos e interpretáveis para sistemas de previsão de cheias.

Palavras-Chave – previsão de cheias, LSTM, tempo de deslocamento.

INTRODUÇÃO

A previsão de cheias é uma atividade central no planejamento e na gestão de recursos hídricos, com implicações diretas na mitigação de riscos hidrológicos, na segurança de populações ribeirinhas e na operação de sistemas hidráulicos. Tradicionalmente, modelos baseados em processos físicos —

¹ Departamento de Engenharia Hidráulica e Recursos Hídricos - UFMG, Av. Pres. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901 rodrigopgb@ufmg.br; ppsolha@gmail.com; brunocivil08@gmail.com; julian.eleuterio@ehr.ufmg.br; afrodrigues@ehr.ufmg.br

como os modelos hidrológicos conceituais e distribuídos — têm sido empregados para simular a resposta hidrológica de bacias hidrográficas a eventos de precipitação. Embora esses modelos ofereçam elevada interpretabilidade física, sua aplicação em contextos operacionais enfrenta limitações relacionadas à elevada exigência de dados de entrada e à complexidade da calibração, especialmente em bacias escassas em dados monitorados.

Nos últimos anos, abordagens baseadas em aprendizado de máquina, e em particular redes neurais recorrentes do tipo Long Short-Term Memory (LSTM), têm demonstrado notável desempenho na previsão de vazões, superando modelos hidrológicos clássicos em diversas métricas de acurácia, sobretudo quando aplicadas a séries históricas de larga escala temporal e espacial (Frame et al., 2022; Kratzert et al., 2019). A arquitetura LSTM é especialmente adequada para a modelagem de sistemas dinâmicos com memória de longo prazo, sendo capaz de capturar relações não lineares e dependências temporais complexas sem a necessidade de especificação explícita das equações de balanço hídrico (Giriagama et al., 2022; Man et al., 2023; Zhang, 2023).

Apesar dos avanços em desempenho preditivo, modelos LSTM ainda enfrentam críticas quanto à sua natureza "caixa-preta", dificultando a interpretação hidrológica dos resultados e limitando sua aceitabilidade em contextos de decisão informada por critérios físicos. Em resposta a essa lacuna, estudos recentes têm explorado formas de incorporar conhecimento hidrológico a priori nas arquiteturas LSTM, seja por meio da análise dos estados internos da rede (Lees et al., 2022), da introdução de atributos fisiográficos como entradas estáticas (Kratzert et al., 2019), ou ainda da imposição de restrições físicas nos fluxos internos da rede (Frame et al., 2022). Essas iniciativas indicam um movimento emergente em direção à modelagem fisicamente embasada com redes neurais, que busca combinar o poder preditivo dos modelos baseados em dados com a coerência dos conceitos hidrológicos estabelecidos.

Dentro desse contexto, destaca-se o potencial de conceitos clássicos como o tempo de deslocamento dos hidrogramas para enriquecer a estrutura de entrada dos modelos LSTM. Tais variáveis, amplamente empregadas na hidrologia de projeto e no delineamento de redes de monitoramento, fornecem uma representação sintética da resposta temporal da bacia e podem orientar a definição da janela temporal relevante para a modelagem. Apesar de sua reconhecida importância física, sua incorporação em modelos baseados em aprendizado profundo permanece incipiente na literatura.

Diante do exposto, o presente estudo tem como objetivo avaliar a aplicabilidade de conceitos hidrológicos clássicos — especificamente o tempo de traslado dos hidrogramas de cheia entre estações — como critério para definir a estrutura de entrada de modelos LSTM. Busca-se verificar se a introdução dessa informação pode reduzir a redundância de dados e melhorar o desempenho preditivo e a coerência hidrológica dos modelos. Para isso, realiza-se um estudo de caso na bacia do rio Piracicaba, em Minas Gerais, combinando análise de sensibilidade hidrológica com experimentos computacionais em redes neurais recorrentes.

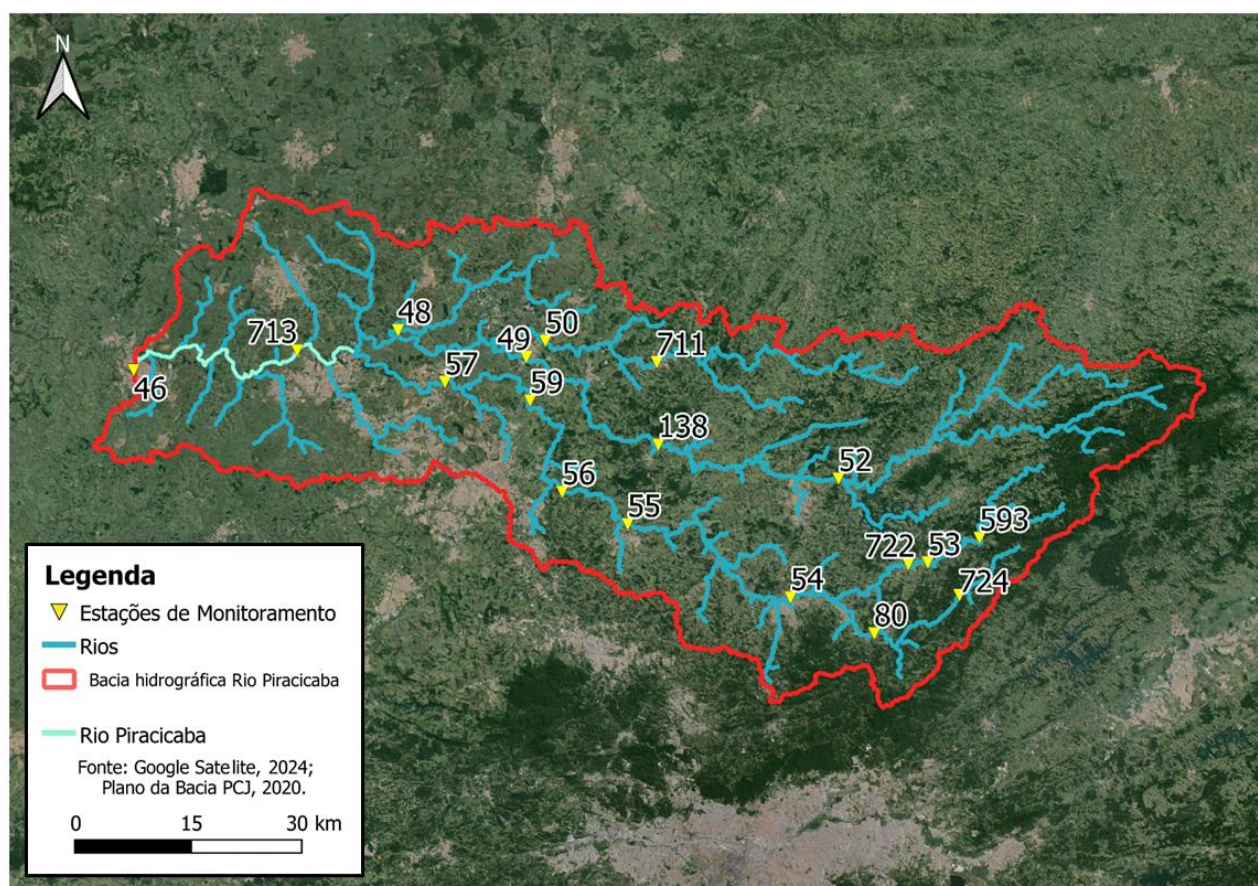
ÁREA DE ESTUDO

A área de estudo de caso selecionada corresponde ao município de Piracicaba, localizado no estado de São Paulo, Brasil. Piracicaba está inserido na bacia hidrográfica dos rios Piracicaba, Capivari e Jundiá (PCJ), a qual abrange uma área total de aproximadamente 15.377 km² e engloba 76 municípios — sendo 71 no estado de São Paulo e 5 em Minas Gerais. A sub-bacia do rio Piracicaba, especificamente, representa cerca de 11.403 km² desse total.

No município de Piracicaba, a área de drenagem contribuinte compreende aproximadamente 8.850 km². Conforme ilustrado na Figura 1, o monitoramento pluviométrico e fluviométrico é realizado pelo Departamento de Águas e Energia Elétrica do Estado de São Paulo (DAEE-SP), por meio de uma rede composta por 18 estações hidrometeorológicas. Essas estações fornecem dados em alta resolução temporal (intervalos de 10 minutos) e apresentam um histórico contínuo entre 1º de janeiro de 2018 e 31 de dezembro de 2023, com percentual de dados ausentes inferior a 5%.

O município possui um histórico documentado de eventos significativos de inundação (Ballester et al., 1998). Em 2010, uma cheia severa afetou áreas urbanas críticas, incluindo a histórica Rua do Porto. Mais recentemente, em setembro de 2023, novas inundações causaram importantes prejuízos socioeconômicos. Esses eventos evidenciam a vulnerabilidade da região a episódios hidrometeorológicos extremos e reforçam a pertinência da bacia do Piracicaba como estudo de caso para a avaliação de sistemas de previsão e alerta de cheias.

Figura 1 – Área de estudo: Bacia do Rio Piracicaba



PROCESSAMENTO DE DADOS

A etapa inicial consistiu no pré-processamento das séries históricas de precipitação e nível das estações da bacia do rio Piracicaba. Para avaliar o percentual de falhas dos dados, foi elaborado um diagrama de Gantt, o qual possibilitou identificar lacunas nas séries temporais e quantificar o número máximo de dias consecutivos com dados ausentes (Figura 2).

Em virtude do elevado número de dias consecutivos sem dados (acima de dois meses), as estações 724 e 722 foram excluídas da base de dados. Para as demais estações, as lacunas foram preenchidas por interpolação linear, tendo em vista que ausências inferiores a três dias consecutivos não comprometem significativamente a dinâmica das vazões em escala horária.

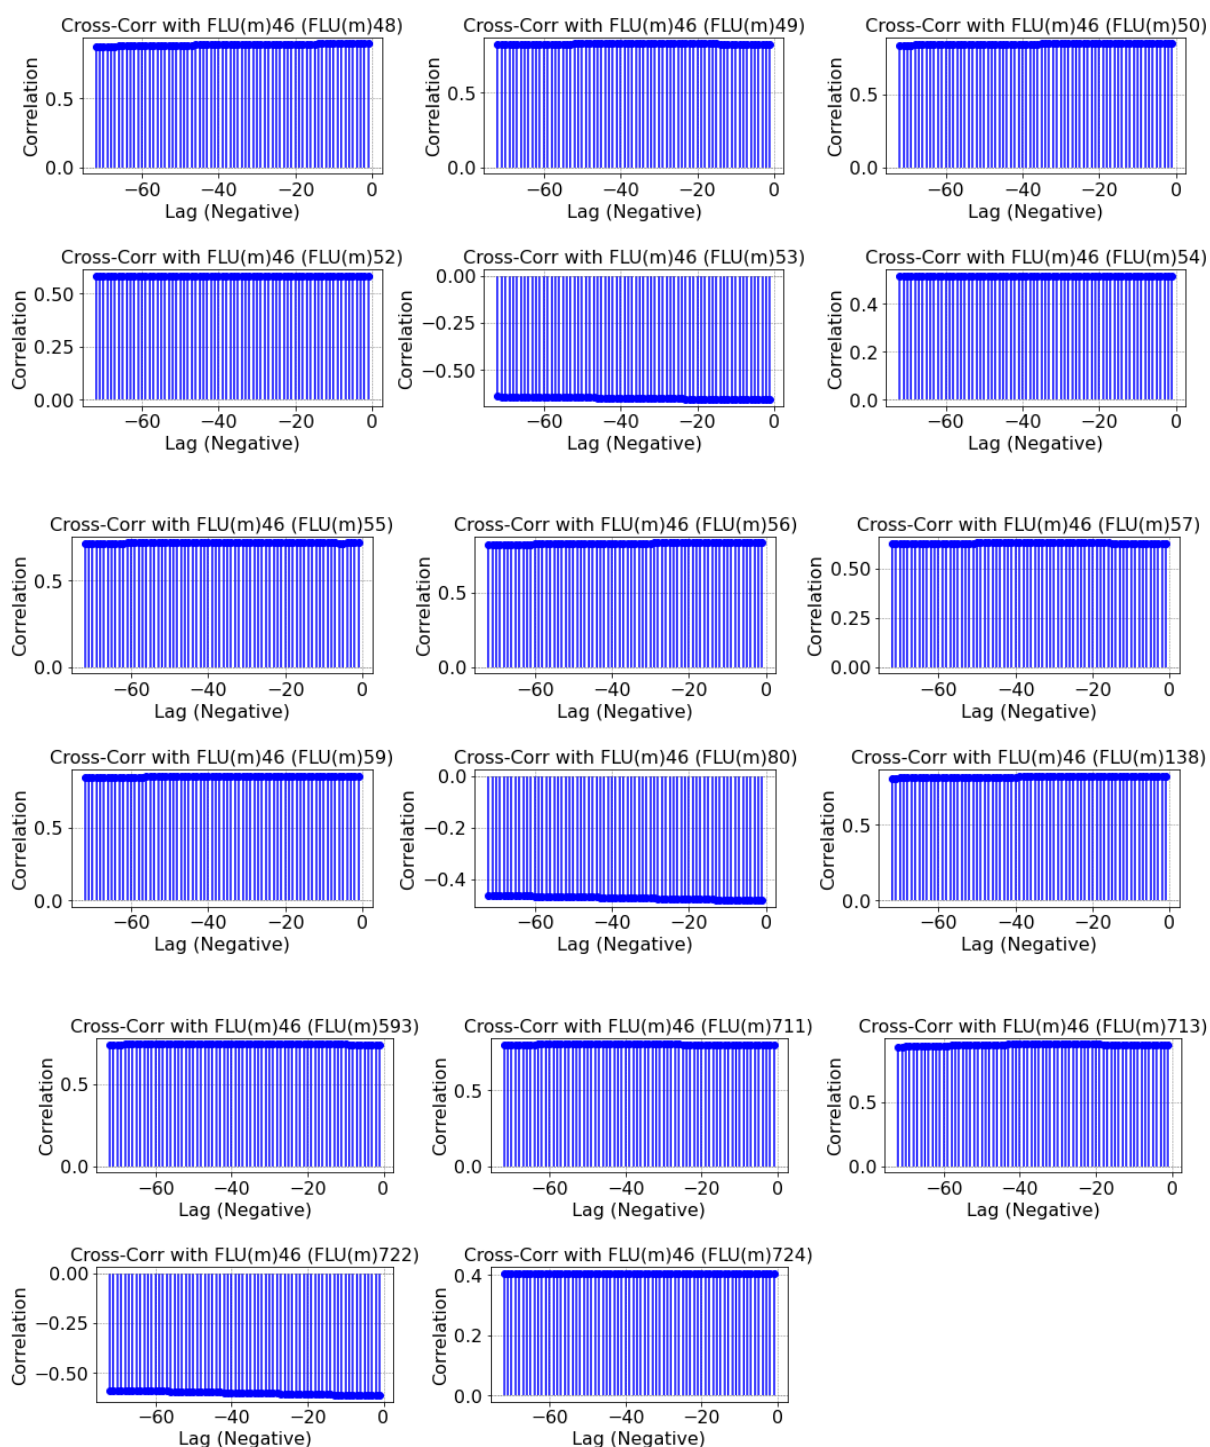
Figura 2 – Disponibilidade Temporal de Dados nas Estações Hidrometeorológicas (2018–2023)



SELEÇÃO DE VARIÁVEIS

A seleção das variáveis preditoras foi realizada com base na análise de correlação cruzada entre cada série candidata e a série fluviométrica na estação objetivo. A função de correlação cruzada foi aplicada de forma sistemática para cada estação, identificando o grau de influência correspondente a a cada estação. Como esperado, as estações mais próximas da seção exutória (como as estações 713, 57 e 49) apresentaram maiores coeficientes de correlação, indicando maior contribuição à previsão. Em contrapartida, estações situadas a montante de reservatórios reguladores apresentaram correlações negativas ou de baixa magnitude (estações 53, 80, 722), possivelmente relacioandas ao regime hidrológico influenciado por tais infraestruturas (Figura 3).

Figura 3 – Correlação cruzada entre estações de monitoramento e estação alvo



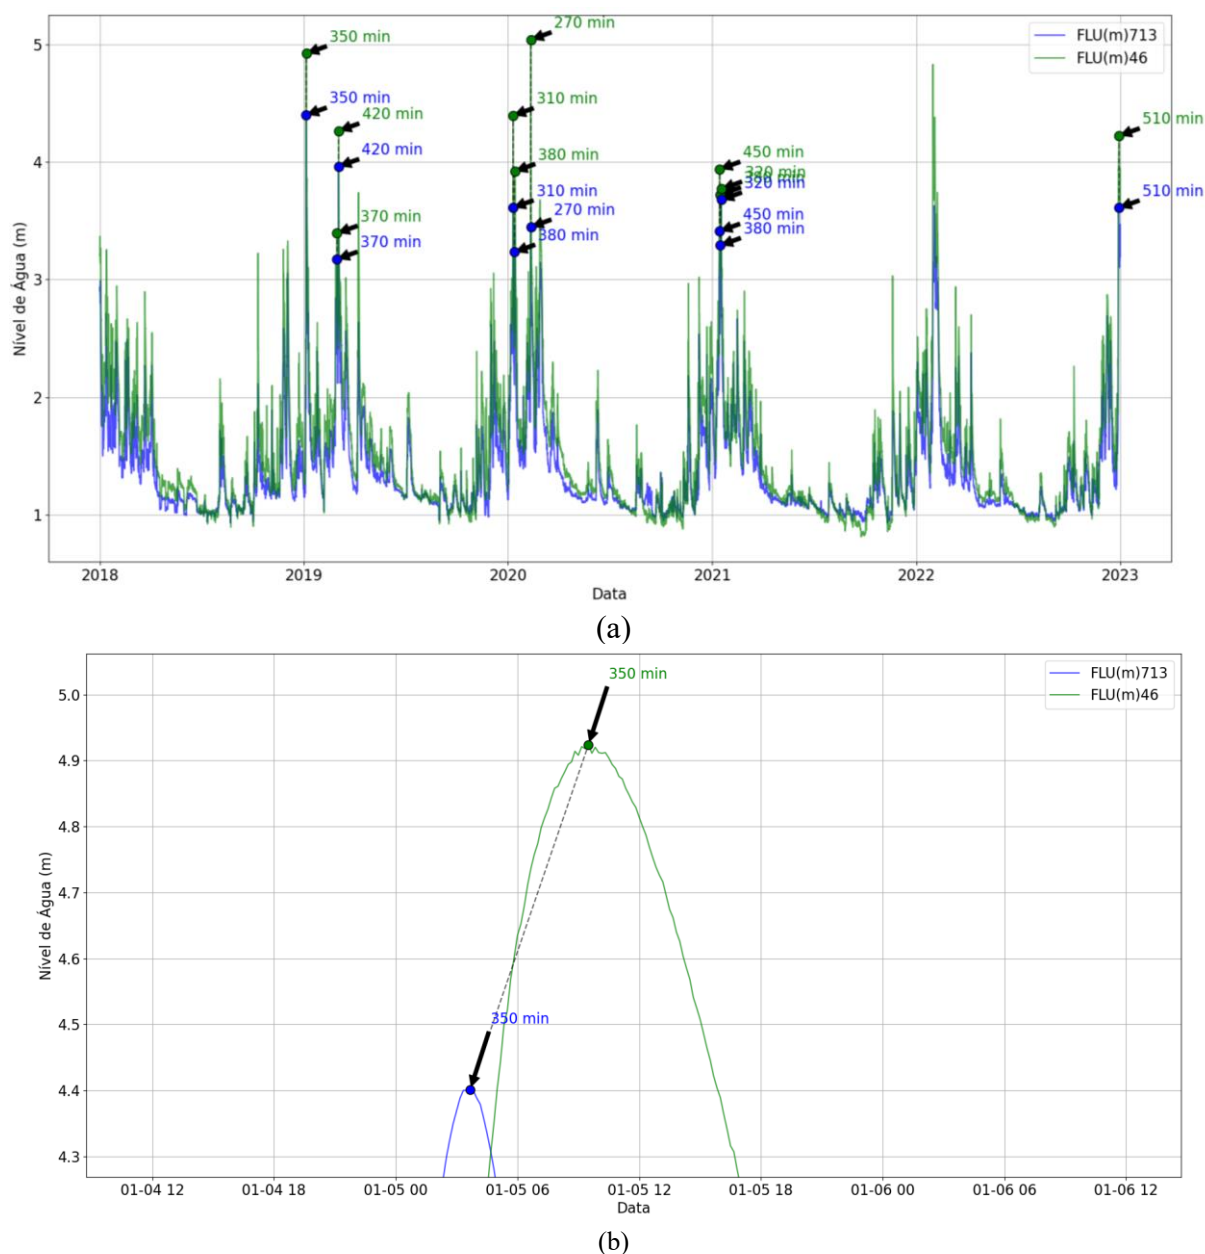
Essa análise embasou a seleção das variáveis que alimentariam o modelo LSTM, priorizando aquelas com maior influência em relação a estação alvo.

DEFASAGEM DOS PICOS DOS HIDROGRAMAS

Com o intuito de fundamentar a definição da janela temporal de entrada do modelo, foi realizada uma análise específica das defasagens entre os picos dos hidrogramas de cheias observados nas estações a montante e na estação exutória. Essa análise permitiu quantificar o tempo médio de deslocamento dos picos de vazão ao longo do curso do rio.

Para cada evento significativo registrado, identificaram-se os instantes de ocorrência dos picos nas estações intermediárias e na estação final. A diferença temporal entre esses picos foi registrada, e os valores médios por estação foram utilizados para determinar o horizonte ideal da janela de entrada do modelo (denotado por H) — isto é, o número de passos temporais retroativos utilizados para compor a matriz de entrada. A Figura 4 apresenta a análise realizada para a estação 713.

Figura 4 – Defasagem dos hidrogramas: Estação 46 x Estação 713: (a) Análise geral, (b) Exemplo de evento 05/2019



TREINAMENTO DO MODELO

Com os dados devidamente preparados e as variáveis de entrada selecionadas, procedeu-se ao treinamento do modelo LSTM. As séries temporais foram particionadas em subconjuntos de treinamento e validação, respeitando a ordem cronológica dos dados. O processo de ajuste foi monitorado por meio da análise das curvas de erro (loss) ao longo das épocas, com o intuito de assegurar a convergência do modelo e mitigar riscos de sobreajuste.

O modelo foi treinado para o horizonte de previsão de 1 hora considerando previsões de curtíssimo prazo. A avaliação de desempenho considerou métricas clássicas da literatura em previsão hidrológica, incluindo o coeficiente de eficiência de Nash-Sutcliffe (NSE), o erro relativo na magnitude do pico de vazão e o erro no tempo de ocorrência do pico. Foram comparados dois cenários de modelagem:

Cenário I – Modelo Base: utilização de todas as séries disponíveis das estações pluviométricas e fluviométricas, com janela temporal de entrada igual a 1 hora.

Cenário II – Modelo Reduzido Fisicamente Embasado: utilização exclusiva da estação 713, com janela de entrada expandida para 6 horas, definida com base na defasagem média observada entre os picos de vazão das estações 713 e 46 (alvo).

RESULTADOS

A Tabela 1 e a Figura 5 apresentam os resultados do desempenho do modelo LSTM nos dois cenários analisados: o Cenário I considerando seis eventos críticos de cheia ocorridos entre 2019 e 2022. As métricas de avaliação adotadas foram o coeficiente de eficiência de Nash-Sutcliffe (NSE) e o erro absoluto da magnitude do pico.

Tabela 1 – Métricas determinadas para previsões de 1 hora de antecedência

Evento	Nash-Sutcliffe		Erro Pico (m)	
	Cen I	Cen II	Cen I	Cen II
1/5/2019	0,955	0,981	0,25	0,13
3/4/2019	0,975	0,977	0,15	0,12
2/10/2020	0,977	0,985	0,40	0,25
1/30/2022	0,893	0,886	0,27	0,15
2/2/2022	0,863	0,986	0,24	0,01
12/29/2022	0,883	0,947	0,11	0,01

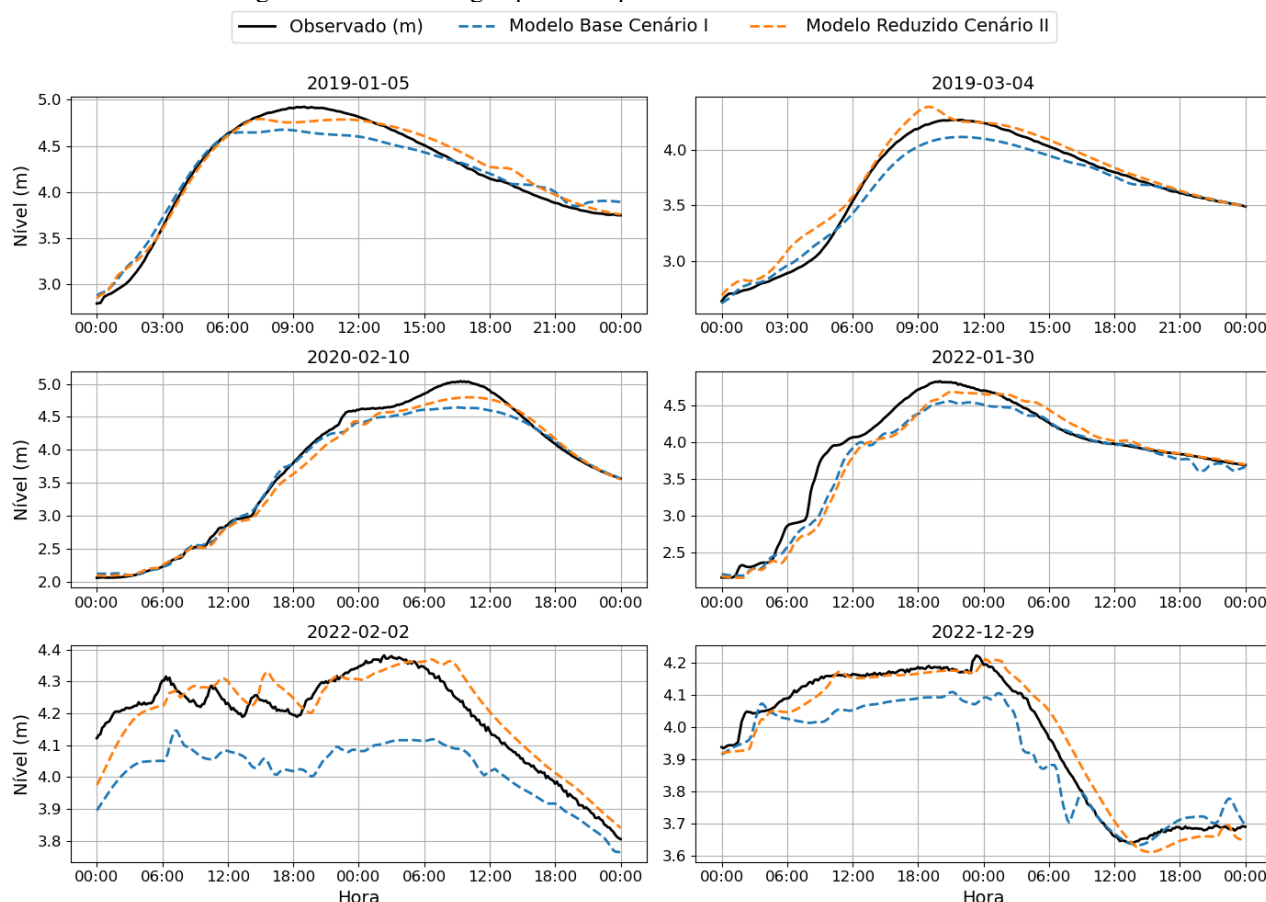
Os resultados revelam que o modelo do Cenário II obteve desempenho superior ou comparável ao do Cenário I na maioria dos eventos analisados. Em termos de NSE, o Cenário II apresentou valores mais elevados em quatro dos seis eventos (05/01/2019, 10/02/2020, 02/02/2022 e 29/12/2022). Especificamente, para o evento de 02/02/2022, o ganho de desempenho foi expressivo: o NSE passou de 0,863 no Cenário I para 0,986 no Cenário II.

No que se refere ao erro da magnitude do pico, o Cenário II também obteve melhor desempenho na maioria dos casos. Em três dos seis eventos, o erro de pico foi reduzido à metade ou mais no modelo reduzido. Novamente, o evento de 02/02/2022 destacou-se, com redução do erro de 0,24 m para apenas 0,01 m.

Esses resultados são especialmente relevantes ao se considerar que o Cenário II utiliza significativamente menos dados de entrada. Ainda assim, o modelo foi capaz de captar com maior precisão os picos de cheia e sua evolução temporal. Essa melhoria pode ser atribuída à janela temporal ampliada (5 horas), que se aproxima do tempo médio de translado das vazões de pico entre as estações e permite ao modelo incorporar, de forma mais eficiente, o comportamento hidrológico antecedente do sistema.

Além disso, é importante destacar que o Cenário II apresenta uma formulação fisicamente embasada, ao incorporar explicitamente a defasagem entre chuvas e resposta hidrológica no processo de modelagem. Ao invés de simplesmente alimentar o modelo com múltiplas variáveis sem distinção espacial ou temporal, o Cenário II estrutura a entrada com base no conhecimento prévio sobre o tempo de propagação dos eventos hidrológicos entre as estações, o que contribui para a sua robustez e capacidade de generalização.

Figura 5 – Níveis de água previstos para horizonte de 1 hora de antecedência



CONCLUSÕES

Este estudo evidenciou a eficácia do uso de Redes Neurais Recorrentes do tipo LSTM para previsão hidrológica de curtíssimo prazo, alcançando coeficientes de eficiência de Nash-Sutcliffe (NSE) superiores a 0,8 na maioria dos eventos avaliados. Tal desempenho destaca o potencial dessa abordagem para aplicações em sistemas de alerta de cheias, sobretudo em bacias com elevada variabilidade hidrológica.

Os resultados demonstraram que a estruturação fisicamente embasada das entradas do modelo contribuiu para a acurácia das previsões, mesmo com um número reduzido de estações pluviométricas. Essa constatação reforça que a qualidade e a pertinência física das variáveis de entrada podem ser mais determinantes que sua quantidade absoluta.

Observou-se, ainda, que o modelo reduzido (Cenário II), alimentado por uma única estação e janela temporal mais ampla, superou o modelo base em termos de NSE e erro do pico em diversos eventos críticos. Esse achado abre caminho para o desenvolvimento de modelos mais enxutos e interpretáveis, com menor dependência de redes densificadas de monitoramento, desde que respeitados os princípios hidrológicos do sistema.

Por fim, destaca-se o potencial de avanços adicionais com a avaliação de cenários intermediários — contemplando mais estações do trecho final do sistema hidrológico — e com a extensão dos horizontes de previsão. Tais explorações podem contribuir para modelos mais robustos e adaptáveis, adequados a distintas escalas de bacia e níveis de complexidade operacional.

AGRADECIMENTOS

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

REFERÊNCIAS

BALLESTER, Maria *et al.* Previsão de Áreas Inundadas na Cidade de Piracicaba (SP) através de Sistema de Informações Geográficas (SIG). *Revista Brasileira de Recursos Hídricos*, v. 3, n. 3, p. 17–27, 1998.

FRAME, Jonathan M. *et al.* Deep learning rainfall–runoff predictions of extreme events. *Hydrology and Earth System Sciences*, v. 26, n. 13, p. 3377–3392, 5 jul. 2022.

GIRIHAGAMA, Lakshika *et al.* Streamflow modelling and forecasting for Canadian watersheds using LSTM networks with attention mechanism. *Neural Computing and Applications*, v. 34, n. 22, p. 19995–20015, nov. 2022.

KRATZERT, Frederik *et al.* Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences*, v. 23, n. 12, p. 5089–5110, 17 dez. 2019.

LEES, Thomas *et al.* Hydrological concept formation inside long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences*, v. 26, n. 12, p. 3079–3101, 20 jun. 2022.

MAN, Yuanyuan *et al.* Enhanced LSTM Model for Daily Runoff Prediction in the Upper Huai River Basin, China. *Engineering*, v. 24, p. 229–238, maio 2023.

ZHANG, Lin. High temporal resolution urban flood prediction using attention-based LSTM models. *Journal of Hydrology*, 2023.