PREVISÃO DE VAZÃO NO RIO SOLIMÕES COM MODELO DE REDES NEURAIS DO TIPO LONG SHORT-TERM MEMORY (LSTM)

Emily Chaves Amâncio[1]; Pedro Luiz Borges Chaffe[2] & Vinícius Bogo Portal Chagas[3]

Palavras-Chave – Previsão de vazão; LSTM; Amazônia; Redes neurais.

INTRODUÇÃO

A previsão de vazões no rio Solimões é crucial para comunidades cuja mobilidade e economia dependem do meio fluvial (Marengo; Espinoza, 2016). Na Amazônia, a hidrodinâmica é caracterizada por planícies inundáveis, efeitos de jusante e curvas-chave em laço (Fassoni-Andrade *et al*., 2021). A representação desses processos por modelos físicos constitui um desafio, sobretudo devido às incertezas dos dados de entrada e à variabilidade temporal dos parâmetros hidráulicos e geométricos.

Modelos de aprendizado profundo, como redes LSTM, destacam-se pela capacidade de extrair relações não lineares entre chuva e vazão a partir de séries temporais (Khandelwal *et al*., 2025). Arquiteturas *encoder–decoder* condensam características fisiográficas e informações hidrológicas em representações das condições iniciais do sistema. Embora apresentem limitações de interpretabilidade e extrapolação, estudos recentes reportam desempenho comparável ou superior ao de abordagens tradicionais (Nearing *et al*., 2024), além da incorporação de atributos fisicamente interpretáveis para aproximar as representações aprendidas dos processos hidrológicos (Vilaseca *et al*., 2023).

Incertezas associadas aos dados hidrometeorológicos influenciam a qualidade das previsões (Paiva *et al*., 2012). Em rios sujeitos a remanso, a relação unívoca entre nível e vazão pode falhar (Paris *et al*., 2016). Dessa forma, séries de vazão obtidas por curvas-chave podem introduzir incertezas. Além disso, métricas como o NSE podem mascarar limitações na representação das componentes interanual e irregular em rios sazonais, tornando relevante a análise das anomalias hidrológicas como variável-alvo (Ruzzante *et al*., 2026), em um contexto de não estacionariedade (Chagas; Chaffe, 2019).

Este trabalho propõe o desenvolvimento de um modelo de previsão de vazão para o rio Solimões, baseado em redes LSTM com arquitetura *encoder–decoder*, para horizontes de 1 a 15 dias. Os objetivos específicos consistem em avaliar a contribuição de atributos derivados fisicamente interpretáveis, a capacidade de generalização frente a eventos extremos, o uso de anomalias hidrológicas como variável-alvo e as incertezas associadas ao uso de séries de vazão e cota.

METODOLOGIA

Área de estudo e dados

A bacia do rio Solimões, integrante da bacia Amazônica, tem área de drenagem de aproximadamente 2,2 milhões de km². O estudo concentrou-se nas estações fluviométricas de Tabatinga e Manacapuru, incorporando, em parte dos experimentos, as séries de vazão de São Paulo de Olivença e Santo Antônio do Içá. Foram utilizados dados de vazão, cota e precipitação da ANA, além de atributos fisiográficos do Copernicus GLO-30. A Figura 1 apresenta a localização das estações.

[1] Graduanda em Engenharia Sanitária e Ambiental, Universidade Federal de Santa Catarina (UFSC); e-mail: emilyamancio123@gmail.com.
[2] Prof. Dr., Departamento de Engenharia Sanitária e Ambiental, Universidade Federal de Santa Catarina (UFSC); e-mail: pedro.chaffe@ufsc.br.
[3] Pós Doutorando, PPGEA, Universidade Federal de Santa Catarina (UFSC); e-mail: vbchagas@gmail.com

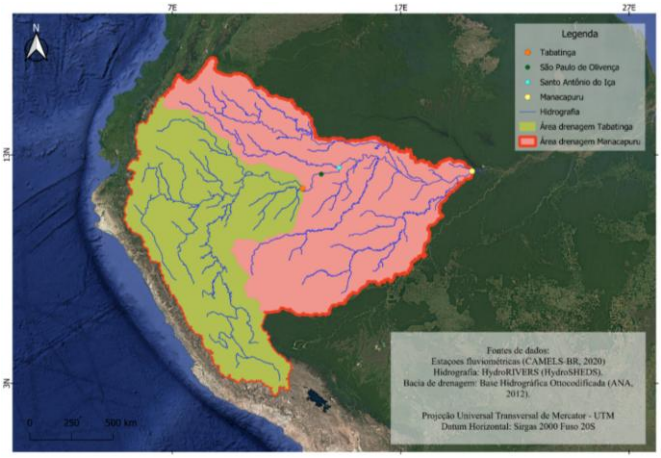


Figura 1. Estações fluviométricas e delimitação das áreas de drenagem das estações-alvo.

Arquitetura do modelo

Adotou-se uma arquitetura *encoder–decoder* baseada em LSTM com mecanismos de atenção. O *encoder* processa o histórico das variáveis e atributos fisiográficos, condensando as informações em estados internos. O *decoder* gera as previsões autorregressivamente, conforme exibido na Figura 2.

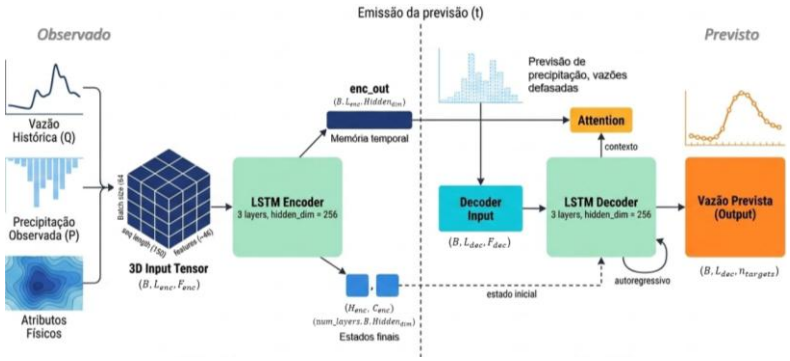


Figura 2. Fluxo de informações na arquitetura encoder–decoder.

Função objetivo

A função de perda combina o erro quadrático médio com termos de regularização baseados em conhecimento hidrológico (Zhang *et al*., 2025). A perda total corresponde à soma ponderada dos componentes, com pesos definidos por hiperparâmetros.

Estratégias de treinamento

A rede empregou três camadas recorrentes empilhadas e espaço oculto de dimensão 256. As séries foram divididas cronologicamente em 90% para treino, 8% para validação e 2% para teste. Para mitigar o sobreajuste, utilizaram-se técnicas de regularização e *teacher forcing*.

Decomposição da variabilidade e métricas de avaliação

A variabilidade hidrológica foi decomposta nas componentes sazonal, interanual e irregular (Ruzzante *et al*., 2026). A fração sazonal da variância, obtida pela climatologia diária, foi adotada como *benchmark*. O desempenho foi avaliado por meio do NSE, RMSE e NSE das anomalias, calculado sobre as séries dessazonalizadas com a climatologia do período de treinamento.

Configuração experimental

Os experimentos foram organizados em etapas, correspondentes aos objetivos específicos. Em cada etapa, mantiveram-se fixas as configurações do modelo, variando-se o aspecto investigado.

RESULTADOS

Decomposição da variabilidade hidrológica

A decomposição das séries de vazão evidenciou a predominância da componente sazonal nas duas estações. Em Tabatinga, a fração sazonal da variância foi de 0,794 e, em Manacapuru, de 0,814, valores equivalentes ao NSE do *benchmark* climatológico (Ruzzante *et al.*, 2026). Esse predomínio tende a inflar o NSE, justificando o uso do NSE das anomalias para avaliar a capacidade do modelo de representar a variabilidade não sazonal.

Avaliação geral do desempenho dos modelos

Em todas as configurações, o NSE superou o *benchmark* climatológico. O NSE das anomalias evidenciou melhor as diferenças entre os experimentos, atingindo 0,844 em Tabatinga e 0,971 em Manacapuru, indicando que o modelo representa parte da variabilidade interanual e irregular. Manacapuru apresentou desempenho superior na maioria dos experimentos, possivelmente devido à disponibilidade de vazões observadas a montante.

Atributos derivados fisicamente interpretáveis

Os experimentos de referência, sem atributos derivados, estiveram entre os menores valores de NSE das anomalias, confirmando sua contribuição para o desempenho do modelo. Os melhores resultados foram obtidos com atributos associados ao estado hidrológico da bacia. A interpretação é reforçada pela comparação entre experimentos que diferem pela inclusão de precipitação acumulada e média antecedente. Em Tabatinga, esses atributos reduziram o NSE das anomalias de 0,844 para 0,755. O melhor desempenho dos atributos derivados da vazão é atribuído à elevada memória hidrológica da bacia amazônica e às incertezas dos dados de precipitação.

Avaliação da capacidade de generalização em eventos extremos

Mesmo com a remoção de eventos extremos e moderados do treinamento, o desempenho foi mantido. No cenário de exclusão mais restritivo, o NSE das anomalias permaneceu elevado, com valor de 0,892 em Tabatinga e 0,993 em Manacapuru.

Os erros na previsão dos eventos removidos do treinamento apresentaram magnitude semelhante à observada no conjunto de teste, sugerindo boa capacidade de generalização. A Figura 3 compara um evento extremo de seca entre o experimento 016, treinado com esse evento, e os experimentos 023 e 025, nos quais foram removidos, respectivamente, 50% e 100% dos eventos moderados e extremos.

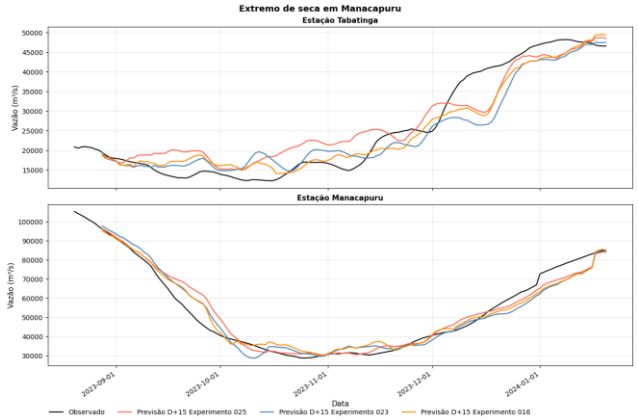


Figura 3. Comparação das previsões para um evento extremo de seca no horizonte de 15 dias.

Apesar de o experimento 016 ter sido treinado com o evento, seu desempenho foi semelhante ao dos experimentos 023 e 025, que não tiveram acesso a ele. Esse resultado sugere que o modelo baseia suas previsões em relações hidrológicas aprendidas, e não na memorização de eventos específicos.

Os maiores desafios concentraram-se nas estiagens, possivelmente devido ao predomínio de processos de resposta lenta não representados pelas variáveis de entrada.

Utilização de anomalias hidrológicas como variável-alvo

O uso de anomalias em relação à sazonalidade como variável-alvo resultou em leve redução de desempenho, sugerindo que a arquitetura é capaz de representar parte da variabilidade não sazonal.

Influência da conversão cota–vazão por curva-chave

No conjunto de teste, os modelos treinados com cota e com vazão apresentaram desempenho semelhante. Na avaliação operacional, o modelo baseado em vazão foi superior. Esse resultado indica que a escolha da variável hidrológica pode influenciar o processo de aprendizagem. Desse modo, os efeitos das incertezas da curva-chave não podem ser avaliados de forma isolada.

CONCLUSÕES

O modelo LSTM teve desempenho superior ao *benchmark* climatológico e foi capaz de representar parte da variabilidade não sazonal das vazões do rio Solimões. A incorporação de atributos derivados fisicamente interpretáveis, principalmente os associados ao estado hidrológico da bacia, aumentou a habilidade preditiva do modelo. Também foi observada boa capacidade de generalização para eventos extremos não observados durante o treinamento. O uso de anomalias hidrológicas como variável-alvo não resultou em ganhos de desempenho. A escolha da variável hidrológica pode influenciar o processo de aprendizagem, não sendo possível avaliar erros de conversão isoladamente. Os resultados reforçam o potencial de modelos LSTM para previsão de vazões em rios amazônicos e evidenciam a importância da seleção de atributos consistentes com os processos hidrológicos dominantes.

REFERÊNCIAS

CHAGAS, V. B. P.; CHAFFE, P. L. B. (2019). "Não-estacionariedade é inevitável! Causas das recentes mudanças de vazão no Brasil" in Anais do XXIII Simpósio Brasileiro de Recursos Hídricos, Foz do Iguaçu, 2019.

FASSONI-ANDRADE, A. C. *et al*. (2021). "Amazon Hydrology From Space: Scientific Advances and Future Challenges". Reviews of Geophysics.

KHANDELWAL, A. *et al*. (2025). Physics Guided Machine Learning Methods for Hydrology.

MARENGO, J. A.; ESPINOZA, J. C. (2016). "Extreme seasonal droughts and floods in Amazonia: Causes, trends and impacts". International Journal of Climatology.

NEARING, G. S. *et al*. (2024). "Global prediction of extreme floods in ungauged watersheds". Nature, v.627, p.559–563.

PAIVA, R. C. D. *et al*. (2012). "On the sources of hydrological prediction uncertainty in the Amazon". Hydrology and Earth System Sciences, v.16, p.3127–3137.

PARIS, A. *et al*. (2016). "Stage-discharge rating curves based on satellite altimetry and modeled discharge in the Amazon basin". Water Resources Research, v.52, p.3787–3814.

RUZZANTE, S. W.; KNOBEN, W. J. M.; WAGENER, T.; GLEESON, T.; SCHNORBUS, M. (2026). "Technical note: High Nash–Sutcliffe Efficiencies conceal poor simulations of interannual variance in seasonal regimes". Hydrology and Earth System Sciences, v.30, p.2337–2355.

VILASECA, F. *et al*. (2023). "Assessing influential rainfall–runoff variables to simulate daily streamflow using random forest". Hydrological Sciences Journal, v.68, p.1738–1753.

ZHANG, T. *et al*. (2025). "Deep learning of flood forecasting by considering interpretability and physical constraints". Hydrology and Earth System Sciences, v.29, p.5955–5974.

AGRADECIMENTOS

Os autores agradecem ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo suporte financeiro.