

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

Simulação de vazão em bacias “sem medições” usando modelos de rede neural LSTM (Long Short-Term Memory) regionalizados no Brasil

*João Maria de Andrade^{1,2}, Alfredo Ribeiro Neto², Rodolfo Nóbrega³, Suzana Maria Gico Lima
Montenegro²*

RESUMO – A previsão de vazão em bacias hidrográficas não monitoradas representa um dos principais desafios da hidrologia, especialmente em países tropicais como o Brasil, onde há escassez de estações de medição de vazão e precipitação. Este estudo avalia o desempenho de modelos baseados em redes neurais do tipo *Long Short-Term Memory* (LSTM) na simulação de vazões em bacias tropicais e subtropicais, utilizando uma base de dados de 200 bacias e classificação hidroclimática baseada no índice de aridez. O modelo foi treinado com dados de forçantes climáticas diárias e atributos fisiográficos das bacias e testado para 40 bacias “não monitoradas”. As análises mostram que o LSTM obteve melhor desempenho em bacias úmidas e muito úmidas, com destaque para regiões do Sudeste e Sul do Brasil, onde foi observado desempenho de $KGE > 0,4$ em 95% das bacias hidrográficas. Cerca de 40% das bacias analisadas apresentaram valores de $KGE > 0,6$ na região semiárida. Mesmo em bacias semiáridas, marcadas por alta intermitência e baixa densidade de monitoramento, o modelo foi capaz de reproduzir eventos de cheia e estiagem em alguns casos. Os resultados indicam que a utilização de LSTM é uma alternativa promissora para ampliar a capacidade de previsão hidrológica em regiões com deficiência de dados, oferecendo suporte à gestão de recursos hídricos, operação de reservatórios e mitigação de desastres naturais.

Palavras-Chave – Aprendizado profundo; Modelagem de chuva-vazão; Precipitação.

ABSTRACT– Streamflow prediction in ungauged catchments remains one of the main challenges in hydrology, especially in tropical countries like Brazil, where there is a scarcity of streamflow and precipitation measurement stations. This study evaluates the performance of Long Short-Term Memory (LSTM) neural network models for simulating streamflow in tropical and subtropical catchments, using a database of 200 basins and a hydroclimatic classification based on the aridity index. The model was trained using daily climate forcing data and physiographic attributes of the basins and tested on 40 ungauged catchments. The results show that LSTM achieved better performance in humid and very humid basins, with particular emphasis on the Southeast and South regions of Brazil, where 95% of the basins reached KGE values greater than 0.4. Additionally, approximately 40% of the analyzed basins in the semi-arid region recorded KGE values above 0.6, demonstrating the model's ability to reproduce flood and drought events even in highly intermittent and poorly monitored basins. These findings highlight the potential of LSTM as a promising alternative to enhance hydrological forecasting capacity in data-scarce regions, offering valuable support for water resources management, reservoir operation, and natural disaster mitigation.

Keywords – Deep learning, Rainfall-runoff modelling; flow simulation; Precipitation.

¹Universidade Federal Rural de Pernambuco (UFRPE), Unidade Acadêmica de Belo Jardim (UABJ).

²Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco (UFPE). joao.jma@ufpe.br; alfredo.ribeiro@ufpe.br; suzanam.ufpe@gmail.com.

³University of Bristol, School of Geographical Sciences, Bristol, BS8 1SS, United Kingdom, r.nobrega@bristol.ac.uk.

1. INTRODUÇÃO

Informações precisas sobre o fluxo diário dos rios são essenciais para o gerenciamento eficaz dos recursos hídricos, a operação de hidrelétricas e a mitigação de riscos relacionados a desastres naturais, como enchentes e secas (Mizukami et al., 2017; Xu et al., 2024). No Brasil, país com forte dependência da geração de energia hidrelétrica, os dados hidrometeorológicos, como registros de vazão e precipitação, desempenham um papel fundamental no abastecimento de água, na produção de alimentos e na gestão energética (Bevacqua et al., 2021). No entanto, o país enfrenta sérios desafios devido à baixa densidade de estações de monitoramento hidrometeorológico. A cobertura atual de postos fluviométricos permanece abaixo do padrão recomendado pela Organização Meteorológica Mundial (WMO), que sugere uma estação para cada 1.000 km², além de enfrentar frequentes lacunas e descontinuidades nos registros de vazão (WMO, 2010; Almagro et al., 2021b).

Diante dessas limitações, a previsão de vazão em bacias hidrográficas não monitoradas continua sendo um dos maiores desafios da hidrologia aplicada (Rakovec et al., 2019). Modelos hidrológicos conceituais tradicionais geralmente exigem calibração específica para cada bacia com base em dados observados de vazão, o que limita sua aplicabilidade direta em regiões sem medições (Xu et al., 2024). Nesse contexto, a Inteligência Artificial (IA), especialmente os métodos de *Deep Learning* (Aprendizado Profundo) como as redes *Long Short-Term Memory* (LSTM), tem se destacado como uma alternativa promissora. Os modelos LSTM são capazes de capturar dependências temporais complexas dos processos hidrológicos, sem a necessidade de formulações físicas explícitas. Desde o trabalho pioneiro de Kratzert et al. (2018, 2019), estruturas baseadas em LSTM têm demonstrado desempenho superior em comparação com modelos hidrológicos tradicionais, tanto na simulação quanto na regionalização de vazões, incluindo aplicações em bacias não monitoradas, por meio da utilização de atributos fisiográficos das bacias e forçantes climáticas como entradas do modelo.

Apesar desses avanços, a aplicação de modelos LSTM em bacias tropicais e subtropicais, como as brasileiras, ainda é limitada e carece de estudos mais aprofundados. Além disso, compreender a capacidade de generalização desses modelos em cenários com escassez de dados, especialmente em regiões hidroclimáticas heterogêneas, é fundamental para o avanço da modelagem hidrológica regional. Diante desse cenário, o principal objetivo deste estudo é avaliar o

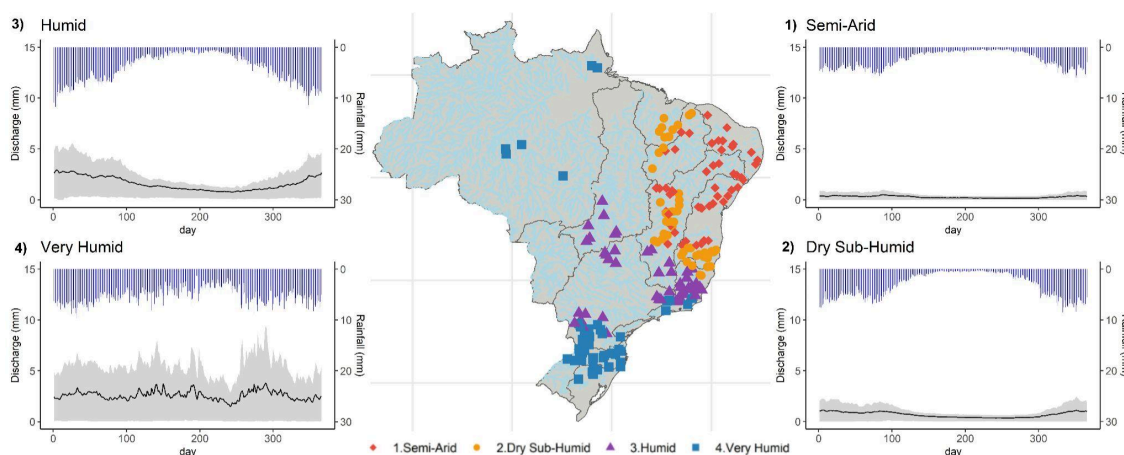
desempenho de modelos LSTM na simulação de vazões em bacias tropicais “não monitoradas”, utilizando uma abordagem de grande amostragem e classificação climática das bacias. Este trabalho busca contribuir para o avanço da modelagem hidrológica orientada por dados e apoiar processos de tomada de decisão em regiões com cobertura limitada de monitoramento hidrométrico.

2. METODOLOGIA

2.1. Área de Estudo e dados

A localização das bacias hidrográficas é apresentada na Figura 1. As bacias hidrográficas estão distribuídas ao longo do território Brasileiro, a precipitação média anual no Brasil pode variar de 750 mm/ano até 2.000 mm/ ano (Andrade et al., 2024a). Os dados foram derivados do Catchment Attributes for Brazil (CABra) que contém atributos e informações hidrometeorológicas de 735 bacias hidrográficas no Brasil (Almagro et al., 2021a). Foram selecionadas as bacias que possuíam mais de 99% dos dados de vazão para o período, totalizando um subconjunto de 515 bacias. Desse conjunto foram selecionadas 50 bacias hidrográficas para cada região climática, totalizando 200 bacias.

Figura 1 – Área de estudo e localização das 200 bacias hidrográficas



As regiões foram classificadas com base no índice de aridez, conforme proposto por Zomer et al. (2022), e categorizadas em quatro classes: semiáridas (Semi-Arid), subúmidas secas (Dry Sub-Humid), úmidas (Humid) e muito úmidas (Very Humid) (Tabela 1). Em cada uma dessas regiões, 40 bacias foram utilizadas para o treinamento dos modelos de rede neural LSTM, enquanto as 10 bacias remanescentes foram consideradas como “não monitoradas” (ungauged). Esse

procedimento visa avaliar a capacidade preditiva do modelo LSTM em cenários típicos de escassez de dados, permitindo analisar sua performance na regionalização de vazões e sua robustez ao extrapolar para bacias sem registros observacionais.

Tabela 1 - Classificação das regiões climáticas com base no índice de aridez

Índice de Aridez	Regiões Climáticas
0.2 - 0.5	Semi-Arid
0.5 - 0.65	Dry sub-humid
0.65 - 1	Humid
>1	Very humid


Fonte: Zomer et al., 2022

Para treinamento do modelo LSTM foram utilizados 2 atributos dinâmicos (precipitação e evapotranspiração diárias) e 16 atributos estáticos das bacias: quatro atributos físicos: área, elevação, declividade e ordem do rio; cinco atributos climáticos: precipitação média e evapotranspiração média, temperatura máxima e mínima, índice de aridez; três hidrológicos: coeficiente de escoamento, índice de fluxo de base, valor médio de escoamento diário em mm; dois parâmetros de cobertura do solo: porcentagem de cobertura urbana e culturas de cobertura, e dois antropogênicos: número de reservatórios e índice de distúrbio hidrológico. Essas informações foram extraídas do CABra (Almagro et al., 2021a).

2.2. LSTM

Uma LSTM (*Long Short-Term Memory*) é uma arquitetura especializada de redes neurais recorrentes (RNN), projetada para armazenar e transmitir informações ao longo de longas sequências temporais por meio de células de memória internas (Hochreiter & Schmidhuber, 1997). O principal diferencial dessas redes está na estrutura de "portas de controle", que regulam o fluxo de informações, permitindo que o modelo retenha ou descarte informações de forma seletiva ao longo do tempo (Olah, 2015) (Figura 2). Essa capacidade as torna particularmente eficazes na modelagem de sistemas dinâmicos com forte dependência temporal e atrasos não lineares entre entrada e resposta, como é o caso da transformação da precipitação em escoamento superficial em bacias hidrográficas

Figura 2 – Estrutura da célula de memória LSTM. Processamento de dados da última etapa de tempo da amostra acima através de uma célula LSTM. Fonte: Adaptado Hashemi et al. (2022)



2.2.1. Configurações dos inputs e abordagens para modelagem da LSTM

Para obter conjuntos de dados de treino, validação e teste, os dados de cada bacia hidrográfica individual são divididos em três conjuntos da seguinte forma: o período mais recente contendo 6 anos de registros de descarga completa é definido como o período de teste (Out–2004 a Set–2010); período de validação (Out–1998 a Set–2010); e o período de treino de 18 anos (Out–1980 a Set–1998). No hiperparâmetro do lookback (duração da sequência de eventos passados das variáveis de entrada) foi utilizado o valor de 60 dias. Para analisar a capacidade do modelo em prever vazões em bacias “sem medições”, das 200 bacias hidrográficas disponíveis, 160 foram utilizadas para treinamento e 40 foram reservadas exclusivamente para avaliação, sendo consideradas como "bacias sem monitoramento".

2.3. Critério de avaliação do modelo


O desempenho da modelagem hidrológica com LSTM foi avaliado utilizando a métrica Kling–Gupta Efficiency (KGE), que varia de $-\infty$ a 1, sendo 1 o valor ideal. O KGE combina três componentes: variabilidade (α), viés (β) e correlação linear (r) entre vazões observadas e simuladas. Conforme Schönfelder et al. (2022), valores acima de 0,75 indicam bom desempenho, entre 0,55 e 0,75 desempenho intermediário, enquanto valores negativos são considerados insatisfatórios.

3. RESULTADOS E DISCUSSÃO

Os resultados indicam que a maioria das bacias hidrográficas apresentou excelente desempenho na simulação de vazões, com destaque para as regiões classificadas como úmidas e muito úmidas. Nessas áreas, observa-se predominantemente um $KGE > 0,3$, especialmente nas bacias do Sudeste e Sul do Brasil, evidenciado pelas tonalidades em azul no mapa. Este bom desempenho pode ser atribuído ao regime hidrológico mais estável, com maior disponibilidade hídrica e maior persistência dos fluxos ao longo do tempo, favorecendo a capacidade do modelo LSTM de capturar padrões temporais e espaciais complexos.

Por outro lado, algumas bacias localizadas nas regiões semiáridas e subúmidas secas (diamantes e círculos) apresentaram desempenho inferior, com valores negativos de ΔKGE , evidenciados pelas tonalidades de laranja e vermelho. No entanto, 40% das bacias apresentam valores de KGE maior que 0,6. Uma possível explicação para essa menor performance está relacionada à intermitência e à variabilidade extrema dos regimes hidrológicos das bacias, caracterizadas por períodos prolongados de estiagem seguidos por eventos intensos de precipitação. Esse comportamento resulta em séries temporais mais esparsas e descontinuidades no fluxo, dificultando a modelagem pelas redes LSTM, que são mais eficientes na detecção de padrões consistentes e persistentes ao longo do tempo. Além disso, o baixo armazenamento natural de água, típico dessas regiões mais áridas, limita a influência dos processos de memória hidrológica (como a umidade do solo e o armazenamento subterrâneo), reduzindo a previsibilidade do escoamento.

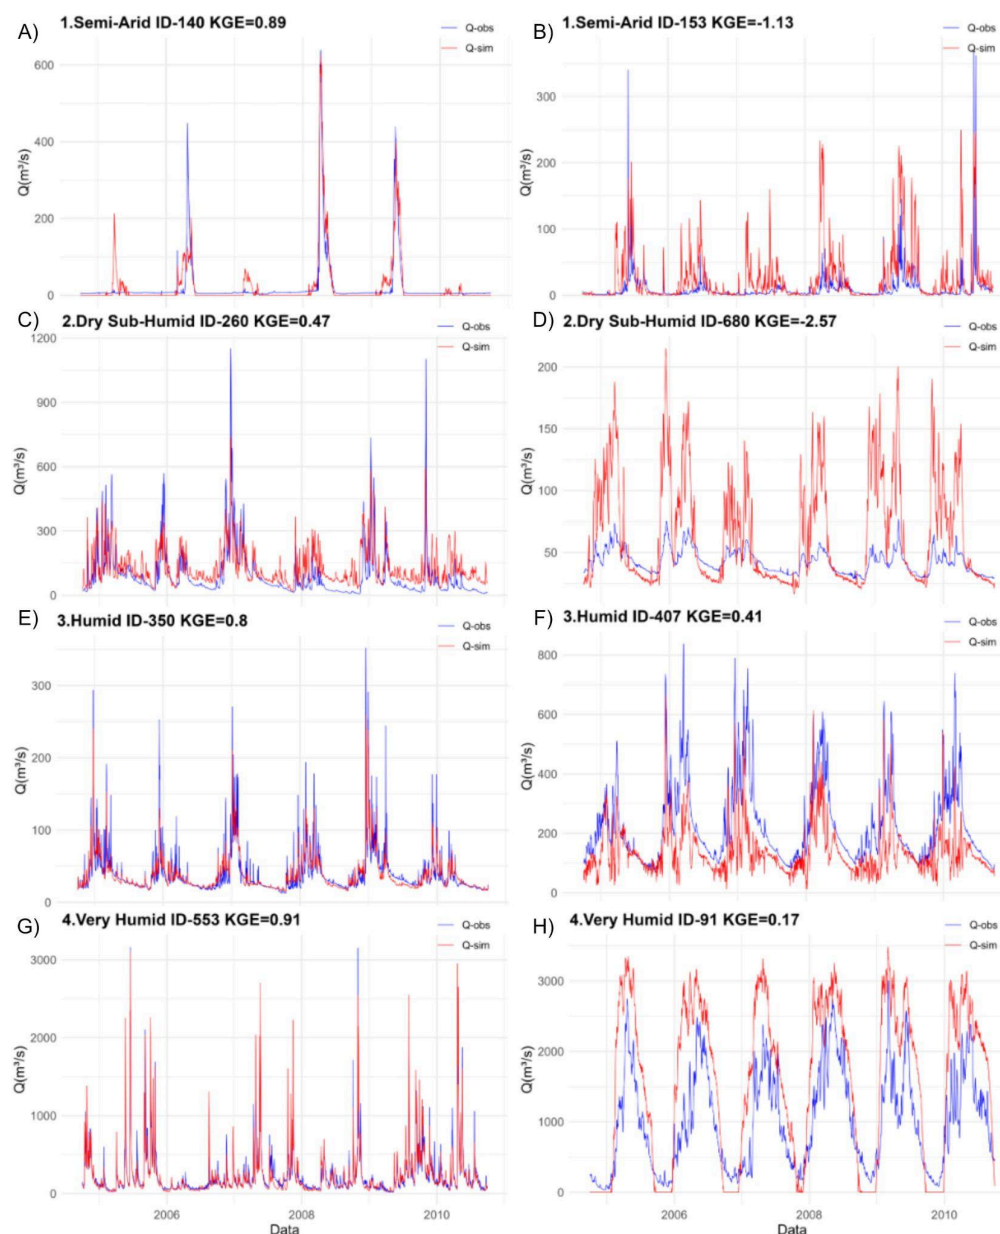
Figura 3 – Desempenho do KGE: A) Distribuição espacial, B) Boxplot.



A Figura 4 apresenta os resultados das simulações de vazão utilizando o modelo LSTM para oito bacias hidrográficas representativas de diferentes regiões climáticas do Brasil (semiárida,

subúmida seca, úmida e muito úmida), foram selecionadas respectivamente uma bacia com melhor e uma com pior desempenho para cada região, com base no valor de (KGE). Nas regiões mais áridas (semiárida e subúmida seca), o desempenho do LSTM foi desafiador devido às características hidrológicas intrínsecas dessas bacias (alta intermitência dos fluxos, reservatórios, eventos de vazão concentrados em poucos episódios de chuva intensa e a escassez histórica de registros contínuos de vazão limitam a capacidade do modelo de aprender padrões robustos).

Figura 4 – Série histórica do $Q(m^3/s)$ KGE do modelo regional de LSTM da fase de teste e os vários descritores de captação utilizados neste estudo para cada uma das 40 bacias estudadas



Apesar dessas dificuldades, é importante destacar que o LSTM obteve desempenho satisfatório em algumas situações. Por exemplo, a bacia ID=140 (Figura 4a) apresentou um excelente resultado, com $KGE=0,89$, demonstrando que, mesmo com a intermitência da série de vazão, o modelo foi capaz de identificar e simular adequadamente os picos de cheia. Por outro lado, em bacias com menor desempenho (ex.: ID=680 - Figura 4d, $KGE=-2,57$), observou-se uma maior dispersão entre os valores simulados e observados, reflexo da dificuldade do modelo em capturar adequadamente os eventos extremos e os períodos prolongados de estiagem. Este comportamento é consistente com os desafios relatados por Nearing et al. (2021), que apontam as bacias áridas como um dos maiores obstáculos para a generalização de modelos baseados em aprendizado profundo.

Nas regiões úmidas e muito úmidas, o desempenho do LSTM foi significativamente melhor. Nessas bacias, a maior regularidade dos fluxos, a presença de fluxo base mais consistente e a melhor disponibilidade de registros históricos de vazão facilitaram o aprendizado dos padrões hidrológicos. A estrutura do LSTM, especialmente o hiperparâmetro *lookback*, permitiu que o modelo se beneficiasse de eventos passados, melhorando a representação dos processos de armazenamento e liberação de água nas bacias (Andrade, 2024b). Um exemplo desse bom desempenho é a bacia ID=553 (Figura 4g), classificada como muito úmida, que apresentou uma excelente correspondência entre os hidrogramas observado e simulado, com $KGE=0,91$.

4. CONCLUSÃO

Os resultados deste estudo demonstram o potencial dos modelos LSTM para a predição de vazão em bacias hidrográficas não monitoradas, com destaque para os bons desempenhos obtidos em regiões tropicais úmidas e subtropicais, como o Sudeste e o Sul do Brasil. Nessas regiões, observou-se uma excelente simulação do escoamento com valor de $KGE>0,4$ para 95% das bacias hidrográficas. De forma geral, cerca de 40% das bacias analisadas apresentaram valores de KGE superiores a 0,6, indicando boa habilidade do modelo em capturar os padrões de vazão diária mesmo na ausência de calibração local para região semiárida.

Esses resultados reforçam a capacidade de generalização do LSTM, especialmente quando utilizado com grandes amostras de dados e variáveis fisiográficas e climáticas como entrada. No contexto brasileiro, onde predominam grandes áreas sem monitoramento fluviométrico contínuo e há forte dependência da água para abastecimento, irrigação e geração de energia hidrelétrica, os

modelos LSTM surgem como uma alternativa promissora. Sua aplicação pode auxiliar gestores públicos e tomadores de decisão, oferecendo suporte técnico para a gestão integrada de recursos hídricos, especialmente em regiões críticas como o semiárido e áreas de expansão agrícola e urbana.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior-Brasil (CAPES)- Código de Financiamento 001 pela bolsa CAPES para o primeiro autor. Este estudo também foi financiado em parte pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), números de concessão 404283/2024-1, 441951/2020-1 e 313392/2020-0, ao primeiro, segundo e o quarto autores agradecem ao CNPq Produtividade em Pesquisa (PQ); Universal MCTIC/CNPq número de concessão 431980/2018-7 e projeto CNPq/MCTIC/ BRICS-STI N° 29/2017 número de concessão 442335/2017-2. E ao INCT Observatório Nacional de Segurança Hídrica e Gestão Adaptativa, financiado pelo CNPq, Proc. 406919/2022-4.

REFERÊNCIAS

- ALMAGRO, A., Oliveira, P. T. S., Meira Neto, A. A., Roy, T., & Troch, P. (2021a). CABra: a novel large-sample dataset for Brazilian catchments. *Hydrology and Earth System Sciences*, 25(6), 3105-3135.
- ALMAGRO, André; OLIVEIRA, Paulo Tarso Sanches; BROCCA, Luca. Assessment of bottom-up satellite rainfall products on estimating river discharge and hydrologic signatures in Brazilian catchments. *Journal of Hydrology*, v. 603, p. 126897, 2021b. doi:10.1016/j.jhydrol.2021.126897.
- ANDRADE, J. M., Neto, A. R., Nóbrega, R. L., Rico-Ramirez, M. A., & Montenegro, S. M. (2024a). Efficiency of global precipitation datasets in tropical and subtropical catchments revealed by large sampling hydrological modelling. *Journal of Hydrology*, 633, 131016.
- ANDRADE, J. M. D. (2024b). Estudos hidrológicos com base em grandes amostras e deep learning: contribuições para aplicações em bacias hidrográficas no Brasil (Master's thesis, Universidade Federal de Pernambuco).
- BEVACQUA, Alena G. et al. Spatial and temporal patterns of propagation from meteorological to hydrological droughts in Brazil. *Journal of Hydrology*, v. 603, p. 126902, 2021. <https://doi.org/10.1016/j.jhydrol.2021.126902>.

HASHEMI, R., Brigode, P., Garambois, P. A., & Javelle, P. (2022). How can we benefit from regime information to make more effective use of long short-term memory (LSTM) runoff models?. *Hydrology and Earth System Sciences*, 26(22), 5793-5816.

HOCHREITER, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02), 107-116.

KRATZERT, Frederik et al. Rainfall-runoff modelling using long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences*, v. 22, n. 11, p. 6005-6022, 2018. <https://doi.org/10.5194/hess-22-6005-2018>.

KRATZERT, Frederik et al. Toward improved predictions in ungauged basins: Exploiting the power of machine learning. *Water Resources Research*, v. 55, n. 12, p. 11344-11354, 2019. <https://doi.org/10.1029/2019WR026065>.

MIZUKAMI, Naoki et al. Towards seamless large-domain parameter estimation for hydrologic models. *Water Resources Research*, v. 53, n. 9, p. 8020-8040, 2017.

NEARING, Grey et al. Global prediction of extreme floods in ungauged watersheds. *Nature*, v. 627, n. 8004, p. 559-563, 2024.

OLAH, Christopher et al. *Understanding lstm networks*. Colah's blog. 2015. Disponível em: <<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acessado em: 10 de Jun. 2024.

RAKOVEC, Oldrich et al. Diagnostic evaluation of large-domain hydrologic models calibrated across the contiguous United States. *Journal of Geophysical Research: Atmospheres*, v. 124, n. 24, p. 13991-14007, 2019.

SCHÖNFELDER, L. H., Bakken, T. H., Alfredsen, K., & Adera, A. G. (2017). Application of HYPE in Norway. SINTEF Energi. Rapport.

XU, Yuanhao et al. Interpretable machine learning on large samples for supporting runoff estimation in ungauged basins. *Journal of Hydrology*, v. 639, p. 131598, 2024.

ZOMER, R. J., Xu, J., & Trabucco, A. (2022). Version 3 of the global aridity index and potential evapotranspiration database. *Scientific Data*, 9(1), 409.

WMO: Guide to the Global Observing System., WMO. 2010.