

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

Modelagem Hidrológica: Comparação entre o Modelo Monte Carlo e um Modelo de Rede Neural do tipo *Multi-Layer Perceptron*

Erickson Johny Galindo da Silva¹ ; André Ferreira Rodrigues² & Bruno Melo Brentan³

Abstract: This study presents a comparative analysis between a physically based lumped hydrological model (MILC) and an artificial neural network model (Multi-Layer Perceptron, MLP) for streamflow forecasting in the Capibaribe River Basin, located in the Brazilian semi-arid region. Using the CAMELS-BR dataset and time series of precipitation, evapotranspiration, and streamflow, the MILC was calibrated via Monte Carlo simulation, while the MLP was trained on normalized time series for 1-day and 7-day forecasting horizons. Results show that while MILC preserves physical consistency, it underperforms in predicting extreme events. In contrast, the MLP yielded better short-term predictions but generated negative streamflow values in longer forecasts, reflecting the lack of embedded physical constraints. The findings indicate low hydrological memory in the basin, which limits model generalization. The study concludes that both models offer complementary strengths and that incorporating explainable artificial intelligence (XAI) techniques can enhance interpretability and decision-making under extreme hydrological scenarios.

Resumo: Este estudo investiga o desempenho comparativo entre um modelo hidrológico concentrado baseado em processos físicos (MILC) e uma rede neural artificial do tipo *Multi-Layer Perceptron* (MLP) na previsão de vazões na bacia do rio Capibaribe, região semiárida do Brasil. Utilizando dados do CAMELS-BR e séries de precipitação, evapotranspiração e vazão, o MILC foi calibrado por simulação de Monte Carlo, enquanto o MLP foi treinado com séries temporais normalizadas para horizontes de predição de 1 e 7 dias. Os resultados mostraram que o MILC possui maior coerência física, porém apresentou limitações na representação dos picos de cheia. O MLP apresentou melhor desempenho preditivo em curto prazo, mas gerou valores negativos de vazão em predições mais longas, indicando a ausência de restrições físicas. A análise revela que a bacia possui baixa memória hidrológica, o que dificulta a generalização dos modelos. Conclui-se que ambos os modelos são complementares e que o uso de técnicas de inteligência artificial explicável (XAI) pode contribuir para melhor interpretar as predições e apoiar a gestão hidrológica em contextos críticos.

Palavras-Chave – Inteligência Artificial, Análise Comparativa, Previsão de Vazão

INTRODUÇÃO

A introdução dos computadores na década de 1960 promoveu uma mudança de paradigma na modelagem hidrológica, possibilitando o uso de equações diferenciais para representar processos contínuos de forma mais fiel à realidade. Nas décadas seguintes, surgiram modelos mais eficientes, com estruturas simplificadas e menor número de parâmetros, como o IPH II (TUCCI *et al.*, 1981). Mais recentemente, o avanço da capacidade computacional e o acesso a grandes volumes de dados

¹) Doutorando do Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais, Av. Antonio Carlos, 6627, Belo Horizonte, 31270-901, Brasil.

²) Professor da Escola de Engenharia da Universidade Federal de Minas Gerais, Av. Antonio Carlos, 6627, Belo Horizonte, 31270-901, Brasil.

³) Professor da Escola de Engenharia da Universidade Federal de Minas Gerais, Av. Antonio Carlos, 6627, Belo Horizonte, 31270-901, Brasil.

hidrometeorológicos têm impulsionado o uso de técnicas de inteligência artificial (IA) na hidrologia, permitindo maior flexibilidade, automação e, em muitos casos, melhor desempenho preditivo.

Dentre os modelos baseados em conceitos hidrológicos clássicos, destaca-se o Modelo Integrado de Lagos e Contribuições (MILC), desenvolvido para representar o balanço hídrico de bacias em regime contínuo. Trata-se de um modelo concentrado e determinístico que considera o armazenamento no solo, a geração de escoamento direto e o retardo da vazão na bacia. Sua estrutura simples, com poucos parâmetros e equações analíticas, favorece a aplicação em regiões com dados escassos ou bacias com baixa densidade de monitoramento, como é comum no semiárido brasileiro. Além disso, por simular o comportamento hidrológico ao longo do tempo, o MILC é particularmente útil em estudos de planejamento e avaliação de cenários hidrológicos de médio e longo prazo Brocca *et al.* (2011).

Em contraste, modelos baseados em redes neurais artificiais, como o *Multi-Layer Perceptron* (MLP), têm ganhado destaque na modelagem hidrológica por sua capacidade de aprender relações complexas e não lineares entre variáveis meteorológicas e hidrológicas. O MLP é composto por camadas interligadas de neurônios artificiais, onde os pesos sinápticos são ajustados por algoritmos de aprendizado supervisionado, como o *backpropagation*. Sua aplicação é vantajosa em problemas com elevada dimensionalidade ou quando os processos físicos são difíceis de representar matematicamente. No entanto, apesar de sua precisão, o MLP apresenta limitações quanto à interpretabilidade física e pode exigir maior cuidado com o pré-processamento dos dados e a validação externa do modelo (Ahmed *et al.*, 2024).

Diante dos desafios impostos pela variabilidade climática e pela escassez de dados em bacias hidrográficas do semiárido brasileiro, como a do rio Capibaribe, torna-se essencial o desenvolvimento e a comparação do desempenho de diferentes abordagens de modelagem hidrológica. Nesse contexto, o presente trabalho tem como objetivo geral comparar o desempenho de um Modelo Concentrado em Regime Contínuo (MILC) com o de um modelo de Rede Neural Artificial do tipo Multi-Layer Perceptron (MLP) na simulação da vazão na bacia hidrográfica do rio Capibaribe.

METODOLOGIA

A fim de proporcionar a aplicação da metodologia em outras áreas de estudo do Brasil e do Mundo, possibilitando a devida comparação de resultados, para o presente trabalho foi utilizada a base de dados desenvolvida por Chagas *et al.* (2020) e denominada Dados Hidrometeorológicos e Atributos de Bacias de Contribuição para Estudos em Larga Escala para o Brasil, do inglês “*Catchment Attributes and Meteorology for Large-sample Studies*” (CAMELS-BR). Este banco de dados, que utiliza padrões internacionais como o CAMELS dos Estados Unidos, Chile e Grã-Bretanha, oferece acesso fácil a um grande conjunto de informações hidrometeorológicas e atributos de bacias de contribuição.

Conforme descrito por Chagas *et al.* (2020), o CAMELS-BR foi desenvolvido a partir de 3.679 postos fluviométricos da Agência Nacional de Águas e Saneamento Básico (ANA). Destes, foram selecionados 897 postos com dados consistentes entre 1990 e 2009 (permitindo compatibilidade com outros conjuntos CAMELS internacionais), cujas bacias de contribuição foram delimitadas por Do *et al.* (2018). As exclusões de postos consideraram erros como dados inconsistentes, medições irrealistas ou erros de instrumentação. A fonte dos dados do CAMELS-BR que foram aplicados nesse artigo são:

- ✓ Precipitação: CHIRPS v2.0 (Funk *et al.*, 2015);

- ✓ Evapotranspiração: real a partir de GLEAM v3.3a (Miralles *et al.*, 2011; Martens *et al.*, 2017);

Neste trabalho, foi utilizado o Modelo Hidrológico Concentrado em Regime Contínuo (MILC), uma versão simplificada do modelo semi-distribuído proposto por Brocca *et al.* (2011), implementado na biblioteca Python *LuMod*, desenvolvida pelo Prof. Saul Arciniega Esparza. O MILC representa o solo como um reservatório único, simulando os fluxos hidrológicos a partir da precipitação, considerando escoamento superficial, infiltração, evapotranspiração real, percolação e escoamento de base.

A geração de escoamento superficial é modelada segundo Georgakakos e Baumer (1996), enquanto os fluxos de percolação e escoamento de base seguem o modelo de Famiglietti e Wood (1994), ambos baseados no grau de saturação do solo e em parâmetros empíricos. A evapotranspiração real é estimada de forma proporcional à evapotranspiração potencial. A transformação da chuva em vazão ocorre por meio do Hidrograma Unitário Instantâneo Geomorfológico (GIUH) para o escoamento direto e do Hidrograma de Nash (NUH) para o escoamento de base.

O processo de calibração foi realizado com 70% dos dados disponíveis, utilizando o método de Monte Carlo para explorar combinações de parâmetros e minimizar o erro via a função objetivo Raiz do Erro Quadrático Médio (RMSE). A validação foi feita com 20% dos dados, com base nos indicadores estatísticos RMSE, Eficiência de Nash-Sutcliffe (NSE) e coeficiente de determinação (R^2). A etapa final envolveu o teste do modelo nos 10% restantes, permitindo avaliar sua capacidade preditiva. A calibração e validação do modelo utilizando MLP que será descrito a seguir também foram avaliados a partir dos indicadores estatísticos RMSE, NSE e R^2 .

A *MultiLayer Perceptron* (MLP) é uma rede neural artificial composta por múltiplas camadas, onde as entradas são valores reais que, ao atravessarem as camadas ocultas, passam por uma combinação linear ponderada por seus respectivos pesos. Na sequência, essas combinações são processadas por uma função de ativação não linear, que transforma os dados antes de produzir a saída final (MEDEIROS *et al.*, 2016).

O funcionamento da MLP pode ser dividido em duas fases principais. A primeira, denominada fase de propagação, consiste no fluxo das informações ao longo das camadas da rede, partindo da entrada até a saída. Durante essa etapa, os pesos permanecem constantes. A segunda fase, conhecida como adaptação, é responsável pelo ajuste dos pesos da rede com o objetivo de minimizar os erros entre as saídas previstas e os valores reais (AMBROSIO, 2019).

A arquitetura utilizada foi uma rede neural do tipo *Multi-Layer Perceptron* (MLP), composta por três camadas ocultas com 64 neurônios cada, ativadas pela função ReLU. A escolha da função ReLU se deve à sua simplicidade computacional e à sua capacidade de introduzir não linearidades, ampliando o poder de generalização do modelo. Foram conduzidas previsões hidrológicas considerando horizontes de 1 e 7 dias à frente, com o objetivo de avaliar a capacidade do modelo em capturar a dinâmica da vazão em diferentes escalas temporais. Para garantir a estabilidade do processo de aprendizado e evitar vieses causados por escalas distintas entre as variáveis, os dados foram normalizados para o intervalo [0, 1]. A normalização foi aplicada separadamente para as variáveis de entrada (precipitação e vazão observada) e para a variável de saída (vazão prevista).

O treinamento da rede foi realizado ao longo de 500 épocas, utilizando como função de perda o Erro Quadrático Médio (MSELoss), que penaliza mais fortemente previsões com grandes desvios em relação aos valores observados. Para otimização dos pesos, foi adotado o algoritmo Adam, com taxa de aprendizado de 0,001, por sua robustez na convergência e adaptabilidade a diferentes gradientes. Durante cada época, os gradientes dos erros foram calculados via retropropagação, e os

pesos atualizados com base na minimização da função de perda. Essa configuração buscou equilibrar complexidade e capacidade de aprendizado, permitindo avaliar o desempenho da rede em dois contextos distintos: a previsão imediata (curto prazo) e a antecipação de tendências em escala semanal (médio prazo). Esse tipo de abordagem é particularmente relevante em bacias do semiárido, onde a variabilidade hidrológica é alta e a previsibilidade limitada.

RESULTADOS


A área de estudo utilizada foi a bacia hidrográfica do rio Capibaribe, que está localizada no estado de Pernambuco e abrange cerca de 7.500 km², atravessando regiões do Agreste e da Zona da Mata até desaguar no Oceano Atlântico, no Recife. O rio Capibaribe é o principal curso d'água, com regime intermitente em suas partes superiores e comportamento mais perene à medida que se aproxima do litoral, devido à maior influência de afluentes e condições climáticas. A bacia é caracterizada por uma combinação de climas semiárido e tropical úmido, além de solos variados e com diferentes tipos de uso, como atividades agrícolas, urbanas e industriais. Apesar de sua importância socioeconômica, a bacia enfrenta desafios relacionados à poluição, desmatamento e pressão hídrica, especialmente em períodos de estiagem prolongada.

A Bacia Hidrográfica do Capibaribe (BHC) possui área de 7557,34 km², com elevação máxima de 1.200,0 m no alto Capibaribe (SRH, 2010). Conforme dados do CAMELS-BR, ela possui 7 postos fluviométricos (39100000, 39130000, 39140000, 3914500, 39150000, 39185000, 39187800) no seu rio principal, denominado Rio Capibaribe, e um (39170000) em um dos seus afluentes, chamado de Rio Tapacurá, conforme Figura 1. A partir da Figura 1 verifica-se também a delimitação da BHC Ottocodificada, assim como sua hidrografia, ambas definidas pela ANA (2021), e a delimitação das áreas de contribuição utilizadas no CAMELS-BR para os postos fluviométricos.

Para o presente trabalho foi selecionada a estação fluviométrica 39130000, localizada no médio Capibaribe nas coordenadas de latitude e longitude, respectivamente, de -8,0128 e 36,0578, e com elevação 366,0 m, conforme CAMELS-BR. Sua área de contribuição possui elevação média de 597,18 m, inclinação média de 53,43 m/km e área de 2.456,72 km². O CAMELS-BR não informa o comprimento do talvegue principal dessa área de contribuição, que foi calculado a partir da hidrografia definida pela ANA (2021) e possui 99,69 km.

As séries de dados de Precipitação, Vazão e Evapotranspiração Real para a Estação Fluviométrica 39130000 e sua área de contribuição possui dados de 01/01/1981 a 31/12/2018, totalizando 37 anos registros, conforme com Figura 2. Na série de dados, destaca-se que a vazão possui vários períodos com dados iguais a zero. O CAMELS-BR apresenta que a vazão média do posto 39130000 é 0,057 mm/d, com razão de escoamento (*runoff*) na área de contribuição (vazão média diária / precipitação média diária) igual a 0,035, vazão com 95% de permanência (Q95) igual a 0 mm/dia e vazão com 5% de permanência (Q5) igual a 0,23 mm/dia, ressaltando que o rio possui longos períodos seca.

Figura 1 – Bacia Hidrográfica do Capibaribe, com hidrografia, postos fluviométricos e suas respectivas áreas de contribuição.




Fonte: Autor (2024)

Como a série de vazão possui falhas significativas a partir de 2011, os dados foram utilizados de 1981 a 2009, totalizando 28 anos de registros. Nesse intervalo de tempo, não há falhas no registro de dados de precipitação e evapotranspiração real, sobretudo, há 0,33% de falhas nos dados de vazão. Esses dados ausentes foram interpolados linearmente. Ressalta-se que a interpolação linear não é a metodologia mais robusta para o preenchimento de falhas diárias de uma série de precipitação ou vazão, sobretudo, por se tratar de um preenchimento para um período com baixa vazão, com valores iguais a zero ou próximo disso, é aceitável a aplicação desse método mais simplório de preenchimento de falhas sem associação de erros significativos nos resultados das séries preenchidas.

O MILC foi executado para 1000 repetições da simulação Monte Carlo, verificando as combinações dos parâmetros nos 70% de dados para calibração, que corresponde ao período de 1987 a 2007, das quais as 20 melhores combinações foram selecionadas com base no coeficiente estatístico RMSE. Selecionadas as 20 melhores combinações, estas foram verificadas nos 20% de dados para validação, que corresponde ao período de 1981 a 1986, com base no mesmo coeficiente estatístico, para definição da melhor combinação. Os intervalos dos parâmetros do MILC adotados na simulação Monte Carlo, bem como o melhor conjunto de parâmetros selecionado entre as 20 melhores combinações, constam na Tabela 1. A partir do melhor conjunto de parâmetros definidos para o MILC na calibração e validação, os dados foram testados para 2019 e 2020.

A análise estatística apresentada na Tabela 2, com um NSE menor que zero na validação e teste, evidencia que a melhor combinação de parâmetros do MILC obtida pela análise de Monte Carlo não representa com fidedignidade os dados reais considerando a alternância entre eventos extremos de cheia e seca. Em contrapartida, as séries de validação e teste, mesmo sem possuir assertividades na magnitude dos eventos de cheia, representaram bem o período de seca, indicando que o MILC tem boa capacidade para prever os períodos em que haverá estiagem.

Figura 2 – Séries de dados de Precipitação, Vazão e Evapotranspiração Real ao longo do tempo para a Estação Fluviométrica 39130000 e sua área de contribuição, conforme CAMELS-BR.



Fonte: Autor (2024)

Tabela 1 – Parâmetros adotados no modelo MILC obtidos a partir da simulação Monte Carlo.

Parâmetro MILC	Intervalo adotado	Melhor combinação de parâmetros
gamma	10 a 25	12,82
m	1 a 20	17,41
ks	100 a 5.000	176,17
alfa	0,1 a 15	11,57
nu	0,01 a 0,4	0,28


Fonte: Autor (2025)

Tabela 2 – Indicadores estatísticos da calibração, validação e teste do MILC com a melhor combinação de parâmetros obtidos a partir da simulação Monte Carlo.

Indicador Estatístico	Calibração	Validação	Teste
NSE	-0,84	0,34	-0,16
R ²	0,24	0,32	0,25
RMSE	8,62	19,98	14,70

A calibração, validação e teste do modelo MILC consta na Figura 3, todos apresentados para a melhor combinação de parâmetros. As séries de calibração e validação não representaram a magnitude dos picos de vazão observados na série real.

Figura 3 – Resultados da calibração, validação e teste do MILC com a melhor combinação de parâmetros obtidos a partir da simulação Monte Carlo.



Fonte: Autor (2024)

Os resultados dos coeficientes estatísticos de eficiência do modelo de rede neural do tipo MLP consta na Tabela 3 para a validação do modelo. Observa-se que, no geral, o modelo apresentou desempenho insatisfatório para predição de longo prazo (7 dias) e resultados estatísticos aceitáveis para as predições de curto prazo (1 dia).

Tabela 3 – Indicadores estatísticos da validação do modelo rede neural do tipo MLP.

Parâmetro Estatístico	Predição 1 dia	Predição 7 dias
NSE	0,93	0,71
R ²	0,93	0,71
RMSE	0,19	0,79


Fonte: Autor (2024)

A Figura 4 apresenta os resultados da simulação hidrológica para horizontes de predição de 1 e 7 dias. Nota-se que, à medida que se amplia o horizonte de previsão, a variabilidade do sinal simulado aumenta, sobretudo em períodos de estiagem. Essa maior dispersão é compatível com o acúmulo de incertezas inerente a previsões em prazos mais longos, e não caracteriza, por si só, a ocorrência de *overfitting*, uma vez que os resultados são oriundos do período de validação.

A presença de valores ligeiramente negativos para a vazão prevista em alguns trechos da série com horizonte de 7 dias evidencia limitações do modelo na representação de vazões muito baixas, possivelmente associadas à ausência de restrições físicas explícitas no processo de modelagem. Ainda

assim, o modelo manteve boa capacidade de captura da dinâmica hidrológica geral, mesmo diante do aumento do intervalo de predição.

Figura 4 – Predição de 1 e 7 dias.



Fonte: Autor (2025)

A análise dos resultados evidencia que a bacia hidrográfica do rio Capibaribe apresenta baixa memória hidrológica, dificultando a previsão de eventos extremos e limitando o desempenho de modelos baseados em padrões históricos. As métricas tradicionais de avaliação, embora indicativas de desempenho médio satisfatório, não capturam adequadamente a resposta do sistema em eventos críticos, como picos de vazão ou estiagens prolongadas. Essa limitação compromete a aplicação dos modelos em contextos de gestão de risco hidrológico.

Comparando o modelo físico-conceitual MILC e a rede neural MLP, observou-se que o MILC, embora mais interpretável e com menor número de parâmetros, mostrou desempenho inferior em termos de generalização, sobretudo em períodos de validação. Já o MLP apresentou melhor desempenho em previsões de curto prazo, com maior capacidade de capturar relações não-lineares. No entanto, sua estrutura sem restrições físicas permitiu a geração de vazões negativas, o que compromete sua aplicabilidade sem ajustes adicionais.

CONCLUSÕES

Este estudo comparou o desempenho do modelo hidrológico concentrado MILC com uma rede neural MLP na previsão de vazões na bacia do rio Capibaribe. Os resultados indicaram que, embora o MILC preserve coerência com processos físicos, apresentou limitações na representação de eventos extremos, como picos de cheia. Já a MLP teve bom desempenho estatístico, principalmente em previsões de curto prazo.

No entanto, a MLP apresentou oscilações em horizontes maiores de previsão, inclusive prevendo valores fisicamente inconsistentes. Isso evidencia a dificuldade de extrapolação de modelos puramente baseados em dados, especialmente em bacias com baixa memória hidrológica.

Sugere-se uma reavaliação da calibração dos modelos, especialmente com um foco separado para calibração, dividindo-a em uma calibração para identificar os períodos e intensidades das cheias e uma calibração para identificar os períodos das estiagens. Dessa forma, acredita-se que será possível minimizar os erros de simulação e melhorar a acurácia dos modelos.

Para avançar, sugere-se o uso de técnicas de inteligência artificial explicável (XAI) para revelar os fatores que mais influenciam as predições da MLP. Isso pode aproximar a modelagem de dados da compreensão hidrológica e apoiar a tomada de decisão em cenários críticos de cheia e seca.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais - FAPEMIG - pelo financiamento para participação no XXVII Simpósio Brasileiro de Recursos Hídricos, concedido através do processo número PCE-00429-25.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO – ANA. *Bacias hidrográficas ottocodificadas do Brasil – Níveis 1 a 12*. Brasília: ANA, 2021. Disponível em: <https://metadados.snirh.gov.br/geonetwork>. Acesso em: 19 jun. 2025.

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO – ANA. *Hidrografia do Brasil ottocodificada: rede hidrográfica vetorial em escala 1:250.000*. Brasília: ANA, 2021. Disponível em: <https://metadados.snirh.gov.br/geonetwork>. Acesso em: 19 jun. 2025.

AHMED, A. A.; SAYED, S.; ABDOULHALIK, A.; MOUTARI, S.; OYEDELE, L. Applications of machine learning to water resources management: a review of present status and future opportunities. *Journal of Cleaner Production*, v. 441, p. 140715, 2024.

AMBROSIO, J. K. *Comitê de máquinas para previsão de demanda de água*. 2019. Tese (Doutorado) — [S.l.]: [s.n.].

CHAGAS, V. B. P. et al. CAMELS-BR: Hydrometeorological time series and landscape attributes for 897 catchments in Brazil. *Earth System Science Data*, v. 12, n. 3, p. 2075–2096, 2020.

FAMIGLIETTI, J. S.; WOOD, E. F. Multiscale modeling of spatially variable water and energy balance processes. *Water Resources Research*, v. 30, n. 11, p. 3061–3078, 1994.

FUNK, C. et al. The climate hazards infrared precipitation with stations – a new environmental record for monitoring extremes. *Scientific Data*, v. 2, p. 1–21, 2015.

GEORGAKAKOS, P.; BAUMER, W. Measurement and utilization of on-site soil moisture data. *Journal of Hydrology*, v. 184, n. 1–2, p. 131–152, 1996.

GLEESON, T. et al. A glimpse beneath Earth's surface: GLoBal HYdrogeology MaPS (GLHYMPS) of permeability and porosity. *Geophysical Research Letters*, v. 41, p. 3891–3898, 2014.

GUPTA, H. V. et al. Large-sample hydrology: a need to balance depth with breadth. *Hydrology and Earth System Sciences*, v. 18, n. 2, p. 463–477, 2014.

HUSCROFT, J. et al. Compiling and mapping global permeability of the unconsolidated and consolidated Earth: GLoBal HYdrogeology MaPS 2.0 (GLHYMPS 2.0). *Geophysical Research Letters*, v. 45, p. 1897–1904, 2018.

- KHOZANI, Z. S. et al. Weekly streamflow forecasting of Rhine river based on machine learning approaches. *Natural Hazards*, p. 1–19, 2024.
- MAIER, H. R. et al. How much X is in XAI: responsible use of ‘explainable’ artificial intelligence in hydrology and water resources. *Journal of Hydrology X*, p. 100185, 2024.
- MARTENS, B. et al. GLEAM v3: satellite-based land evaporation and root-zone soil moisture. *Geoscientific Model Development*, v. 10, p. 1903–1925, 2017.
- MEDEIROS, R. Á. O. et al. Previsão de demanda a médio prazo aplicada em dados reais do sistema de distribuição: uma comparação entre RNA e Lógica Fuzzy. *Revista Principia*, n. 31, p. 77–87, 2016.
- MIRALLES, D. G. et al. Global land-surface evaporation estimated from satellite-based observations. *Hydrology and Earth System Sciences*, v. 15, p. 453–469, 2011.
- “MILC – *Modello Idrologico Lumped in Continuo*”. Disponível em: https://zaul_ae.gitlab.io/lumod-docs/models/milc/. Acesso em: 19 jun. 2025.
- ROUSE, R. E. et al. Streamflow prediction using artificial neural networks and soil moisture proxies. *Environmental Data Science*, v. 4, p. e5, 2025.
- SECRETARIA DE RECURSOS HÍDRICOS – SRH. *Plano hidroambiental da bacia hidrográfica do Capibaribe: cenários tendenciais e sustentáveis*. Recife: PROJETEC – BRLi, 2010. v. Tomo II. 190 p.
- TUCCI, C. E. M.; SANCHEZ, J.; LOPES, M. Modelo matemático precipitação-vazão IPH II. *Cadernos de Recursos Hídricos*, n. 3, 1981.