

Submetido 09/06/2024. Aprovado 20/03/2025

Avaliação: revisão duplo-anônimo

Previsão de vazão de rios usando rede perceptron multi-camada otimizada por neural architecture search

RIVER FLOW FORECASTING USING A MULTI-LAYER PERCEPTRON NETWORK. OPTIMIZED BY NEURAL ARCHITECTURE SEARCH

PREDICCIÓN DEL CAUDAL DE RÍOS USANDO UNA RED PERCEPTRÓN MULTICAPA OPTIMIZADA POR NEURAL ARCHITECTURE SEARCH

Eduardo Henrique Próspero Souza
Instituto Federal do Espírito Santo (Ifes)
duvrxd@gmail.com

Vinicius Marques de Oliveira
Petrobras
vinicius.armlock@hotmail.com

Jefferson Oliveira Andrade
Instituto Federal do Espírito Santo (Ifes)
jefferson.andrade@ifes.edu.br

Karin Satie Komati
Instituto Federal do Espírito Santo (Ifes)
kkomati@ifes.edu.br

Resumo

Este estudo propõe um modelo de rede neural otimizada pela abordagem de Neural Architecture Search (NAS) para a previsão da vazão de água de rios, utilizando dados de estações fluviométricas localizadas em seus afluentes. Os dados dessas estações são modelados como séries temporais multivariadas e servem como entrada para uma rede neural do tipo Perceptron Multicamada. Utilizaram-se duas bases de dados de rios: Rio Itapemirim e Rio Acre. Os resultados dos experimentos demonstram a capacidade dessa abordagem em capturar a complexidade e variabilidade dos dados de vazão dos rios, alcançando coeficientes de determinação (R^2) de 0,999 para o Rio Itapemirim e 0,975 para o Rio Acre. Esses resultados evidenciam que a rede neural tem uma alta capacidade de modelar a complexidade e variabilidade dos dados de vazão tanto do Rio Itapemirim quanto do Rio Acre.

Palavras-chave: série temporal multivariada; coeficiente de determinação; Rio Itapemirim; Rio Acre.

Abstract

This study proposes a neural network model optimized through the Neural Architecture Search (NAS) approach for forecasting river water flow using data from fluviometric stations located along tributaries. The data collected from these stations are represented as multivariate time series and serve as input to a Multilayer Perceptron (MLP) neural network. Two river basins were considered: the Itapemirim River and the Acre River. The experimental results demonstrate the effectiveness of the proposed approach in capturing the complexity and variability of river flow data, achieving coefficients of determination (R^2) of

0.999 for the Itapemirim River and 0.975 for the Acre River. These findings highlight the high modeling capacity of the neural network for accurately representing flow dynamics in both basins.

Keywords: multivariate time series; coefficient of determination; Itapemirim River; Acre River.

Resumen

Este estudio propone un modelo de red neuronal optimizado por el enfoque NAS (Neural Architecture Search) para predecir el caudal de agua de los ríos utilizando datos de estaciones hidrométricas ubicadas en sus afluentes. Los datos de estas estaciones se modelan como series temporales multivariadas y sirven como entrada para una red neuronal Perceptrón Multicapa. Se utilizaron dos conjuntos de datos de ríos: el río Itapemirim y el río Acre. Los resultados experimentales demuestran la capacidad de este enfoque para capturar la complejidad y variabilidad de los datos de caudal de los ríos, logrando coeficientes de determinación (R^2) de 0,999 para el río Itapemirim y 0,975 para el río Acre. Estos resultados indican que el modelo de red neuronal captura eficazmente la complejidad y variabilidad de los datos de caudal. El estudio concluye que el enfoque optimizado de la red neuronal muestra un potencial significativo para la predicción precisa del caudal de los ríos.

Palabras clave: serie temporal multivariada; coeficiente de determinación; Río Itapemirim. Río Acre

Introdução

Diversas cidades brasileiras enfrentam desafios ambientais significativos em virtude da sua proximidade com os rios. Um dos principais problemas é a ocorrência de inundações, que resultam em perdas materiais e, em casos extremos, em perdas de vidas humanas (Saito *et al.*, 2023). Esses eventos têm impactos negativos tanto do ponto de vista socioeconômico quanto na qualidade de vida das populações afetadas (Farias; Mendonça, 2022). Nesse contexto, a capacidade de prever a possibilidade de inundações torna-se essencial para a implementação de medidas preventivas eficazes e para a mitigação dos danos. A utilização de tecnologias de monitoramento e modelagem, aliada a políticas públicas adequadas, pode contribuir significativamente para a redução dos riscos e para a proteção das comunidades vulneráveis.

O monitoramento hidrometeorológico consiste na observação contínua dos diferentes estágios do ciclo da água na superfície terrestre e na atmosfera (Agevap, 2024). A gestão desses dados envolve atividades de coleta, processamento, armazenamento, recuperação e disponibilização de informações históricas sobre as condições atmosféricas e a vazão dos rios. A vazão, por sua vez, é definida como a quantidade de fluido que atravessa uma determinada seção de escoamento. Esse processo é realizado por meio de uma rede de estações hidrométricas, que inclui estações pluviométricas para medir a precipitação, estações fluviométricas para monitorar o fluxo dos rios e estações meteorológicas para registrar dados climáticos.

O conhecimento da vazão de um rio ou de um corpo d'água é fundamental para a elaboração de planos de gestão sustentável, o controle de enchentes, o dimensionamento de barragens, a concessão de outorgas e a resolução de conflitos hídricos entre diferentes usuários de água, como a agricultura, o consumo humano e a dessedentação de animais (Andrade, *et al.*, 2017). Em termos fluviométricos, a vazão corresponde ao volume de água que escoar por uma seção do rio em um determinado intervalo de tempo.

A previsão da vazão da água em um rio, a partir dos dados obtidos por estações fluviométricas, pode ser modelada como um problema de séries temporais multivariadas (Lima; Marques; Orth, 2023). A previsão de séries temporais consiste em analisar

e modelar dados sequenciais registrados ao longo do tempo, com o objetivo de realizar projeções futuras com base nos padrões históricos. Uma série temporal univariada é definida como uma sequência de pontos de dados organizados em ordem sucessiva no tempo (Morettin; Toloi, 2018). Já uma série temporal multivariada envolve múltiplas variáveis dependentes do tempo, nas quais cada variável pode depender não apenas de seus próprios valores anteriores, mas também dos valores anteriores das demais variáveis (Morettin; Toloi, 2020). Em geral, uma série temporal é constituída por amostragens realizadas em pontos sucessivos igualmente espaçados no tempo, caracterizando uma sequência de dados em tempo discreto (Oliveira; Komati; Andrade, 2021).

Modelos de redes neurais têm se mostrado promissores na previsão de séries temporais multivariadas, sendo capazes de capturar relações não lineares entre variáveis que não são facilmente tratáveis por modelos estatísticos tradicionais (Gonzalez-Vidal; Jimenez; Gomez-Skarmeta, 2019). No entanto, o desempenho desses modelos depende da escolha adequada da arquitetura, motivo pelo qual muitos trabalhos recentes se dedicam a comparar e propor novas configurações para diferentes tipos de problemas. Embora seja possível otimizar os parâmetros por meio da experimentação, Miikkulainen *et al.* (2019) argumentam que a abordagem de tentativa e erro é dispendiosa, especialmente em redes neurais que envolvem centenas de milhares de hiperparâmetros.

Uma abordagem para encontrar a melhor arquitetura de rede neural é o AutoML (aprendizado de máquina automatizado), que consiste na automação total ou parcial da aplicação de métodos de aprendizado de máquina a um problema (Telikani *et al.*, 2021). O *AutoML* pode ser implementado por meio de duas tarefas principais: o Neural Architecture Search (NAS) e a otimização de hiperparâmetros (Hutter; Kotthoff; Vanschoren, 2019). O NAS busca automatizar a definição da topologia das redes neurais artificiais, enquanto a otimização de hiperparâmetros refere-se à seleção do conjunto de parâmetros que maximiza o desempenho do modelo de aprendizado.

O objetivo deste trabalho é desenvolver e avaliar modelos de redes neurais artificiais (RNA) do tipo Perceptron Multicamadas (MLP, do inglês *Multilayer Perceptrons*), otimizados por meio da abordagem de NAS, para o problema de predição da vazão de rios. O estudo amplia a pesquisa de Souza *et al.* (2023), que havia proposto um modelo MLP otimizado por NAS com base na implementação de Oliveira, Komati e Andrade (2024), utilizando dados do Rio Itapemirim e avaliação baseada no coeficiente de determinação (R^2). A nova pesquisa expande o escopo do trabalho anterior ao incorporar: (i) um conjunto de dados ampliado para o Rio Itapemirim, (ii) uma nova base de dados para o Rio Acre e (iii) a inclusão da métrica RMSE (*Root Mean Squared Error*, em português, Raiz do Erro Quadrático Médio).

Este artigo está organizado da seguinte forma: na Seção 2, são apresentados os conceitos de NAS e MLP; na Seção 3, são descritos os trabalhos relacionados; a Seção 4 aborda os materiais e métodos utilizados nos experimentos; a Seção 5 apresenta os resultados obtidos; e, por fim, a conclusão é discutida na Seção 6.

Fundamentação teórica

Esta seção apresenta detalhes sobre o modelo MLP e a abordagem de NAS, dispondo sobre os principais conceitos teóricos que fundamentam o desenvolvimento deste trabalho.

Multilayer Perceptrons (MLP)

O MLP é um tipo de RNA composta por neurônios organizados em uma camada de entrada, uma ou mais camadas ocultas totalmente conectadas e uma camada de saída (Park; Lek, 2016). A camada de entrada recebe os dados iniciais, seguida pelas camadas ocultas, que processam as informações da camada anterior aplicando uma função de ativação à soma ponderada das entradas em cada neurônio, o que introduz não-linearidades essenciais para o aprendizado de padrões complexos. A quantidade de neurônios nas camadas ocultas é um fator importante no MLP, pois influencia a capacidade do modelo de capturar padrões nos dados. Um número maior de neurônios pode aumentar a expressividade da rede, mas também eleva o risco de sobreajuste. Por fim, a camada de saída gera a resposta final do modelo, cujo número de neurônios varia conforme a tarefa específica.

O funcionamento do MLP inicia-se com a propagação direta, na qual os dados de entrada atravessam a rede camada por camada. Cada neurônio calcula a soma ponderada de suas entradas e aplica uma função de ativação, como ReLU, *sigmoid* ou *tanh*, para gerar sua saída. A diferença entre a saída predita pela rede e o valor real é avaliada por meio de uma função de perda, como erro quadrático médio ou entropia cruzada. Esse erro é então propagado para trás na rede durante o processo de retropropagação (*backpropagation*), no qual os pesos das conexões são ajustados para minimizar a função de perda. A propagação direta e a retropropagação são repetidas ao longo de diversas iterações, ou épocas, até que a rede aprenda a mapear adequadamente as entradas para as saídas. O número máximo de iterações define o limite para o treinamento: valores altos podem levar ao sobreajuste, enquanto valores baixos podem impedir a convergência adequada do modelo.

O algoritmo de retropropagação utiliza o gradiente da função de perda em relação aos pesos da rede para atualizá-los de forma iterativa. A taxa de aprendizado controla a magnitude dessas atualizações, determinando o tamanho dos passos que o algoritmo de otimização realiza ao percorrer o espaço da função de erro em busca dos pesos que minimizem a perda. A escolha do otimizador, como o Stochastic Gradient Descent (SGD) ou o Adam, influencia diretamente a eficiência e a eficácia do treinamento. Além disso, o parâmetro *alpha*, também denominado termo de penalidade, é utilizado para restringir o tamanho dos pesos, contribuindo para a prevenção do sobreajuste (*overfitting*).

Haykin (2001) destaca que o MLP se sobressai como um modelo não linear geral, com capacidade de aprender padrões complexos sem apresentar viés indutivo. O viés indutivo ocorre quando um algoritmo de aprendizado de máquina busca, a partir de um conjunto de dados de treinamento, a hipótese que melhor descreva as relações entre os objetos e se ajuste aos dados (Bachmann; Anagnostidis; Hofmann, 2024). No entanto, o MLP apresenta algumas limitações: em geral, requer uma quantidade substancial de dados para generalizar adequadamente, bem como outros modelos de aprendizado profundo. Além disso, seu desempenho pode ser sensível à escolha dos hiperparâmetros.

Neural Architecture Search (NAS)

O Neural Architecture Search (NAS) é uma abordagem no campo do aprendizado de máquina que visa automatizar o processo de criação de arquiteturas de redes neurais profundas. Antes do surgimento dessa técnica, o design de modelos de aprendizado profundo dependia de conhecimento técnico especializado e de um processo manual de experimentação e ajuste de parâmetros. Pesquisadores precisavam explorar diversas combinações de configurações e ajustar hiperparâmetros para cada aplicação específica (Zoph; Le, 2016). O NAS introduz um método automatizado que permite a exploração sistemática de espaços de arquitetura, identificando configurações adequadas para problemas específicos. Essa abordagem reduz a necessidade de intervenção manual e possibilita a construção de modelos com desempenho competitivo em menos tempo.

O NAS é uma abordagem que automatiza o processo de definição de arquiteturas de redes neurais, operando de maneira iterativa. Algoritmos de busca exploram um espaço predefinido de arquiteturas, testando diferentes configurações e selecionando aquelas que melhor atendem a critérios como precisão, desempenho computacional e eficiência no uso de recursos (Brandão; Correa; Guedes, 2023). A cada iteração, as arquiteturas candidatas são avaliadas, e os resultados orientam a escolha das próximas configurações, permitindo o ajuste até a identificação de uma solução adequada para o problema.

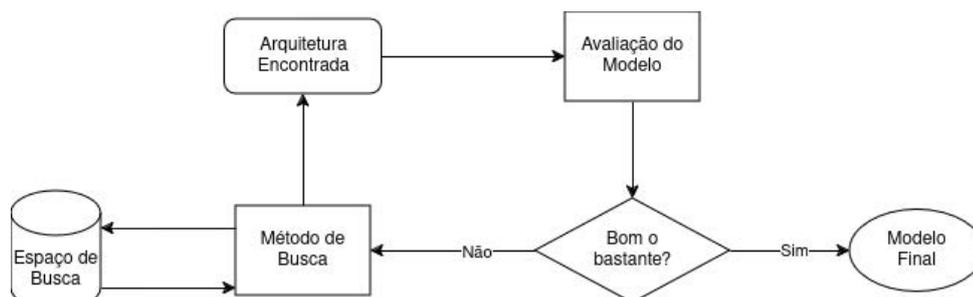


Figura 1 – Diagrama da técnica de NAS

Fonte: Elaborado pelos(as) autores(as).

Conforme ilustrado na Figura 1, o processo de NAS organiza-se em três componentes principais: espaço de busca, estratégia de busca e estratégia de estimativa de desempenho (Elsken; Metzen; Hutter, 2019). O espaço de busca define as arquiteturas possíveis, especificando os hiperparâmetros e suas combinações permitidas. A estratégia de busca é o método utilizado para explorar esse espaço de forma eficiente, evitando a estagnação em ótimos locais e promovendo a diversidade entre as configurações testadas. Já a estratégia de estimativa de desempenho é responsável por avaliar as arquiteturas candidatas e guiar a seleção das melhores alternativas, visando identificar o modelo com maior capacidade preditiva. Finalizada a busca, a arquitetura escolhida é utilizada para treinar o modelo definitivo, cujos resultados de previsão são registrados para análise e validação posteriores.

Trabalhos correlatos

O artigo de Suddul *et al.* (2020) propõe uma abordagem híbrida baseada em otimização evolutiva para a previsão em tempo real de inundações em rios. A metodologia combina variações do modelo MLP com algoritmos de otimização: o Algoritmo

Genético (GA) e o Algoritmo dos Morcegos (BA). Foram desenvolvidos e avaliados quatro métodos: MLP com otimização manual, MLP otimizado por GA (MLP-GA), MLP treinado com BA (MLP-BA) e uma abordagem híbrida (MLP-BA-GA). Os experimentos utilizaram dados hidrológicos de uma rede de sensores do Rio Dee, no País de Gales, Reino Unido. Os resultados indicam que o modelo híbrido MLP-BA-GA apresentou o melhor desempenho, alcançando 99,86% de precisão (coeficiente R^2) no conjunto de validação, superando tanto os modelos tradicionais quanto os otimizados individualmente por GA e BA. Embora o custo computacional na fase de treinamento seja elevado, o modelo final é considerado adequado para implementação em sistemas de alerta em tempo real.

O objetivo do trabalho de Santos-Neto *et al.* (2021) foi apresentar uma proposta de criação de um modelo hidroclimatológico da bacia do Rio Acre, utilizando RNA do tipo MLP. Dados mensais de temperatura da superfície do mar dos oceanos Pacífico e Atlântico tropicais, além do Atlântico Sudoeste, bem como da pressão média mensal em Darwin e Taiti, no período de 1971 a 2016, foram utilizados como entradas para a RNA. A base de dados contém 552 registros, sendo 87% usados para treinamento e 13% para teste. As previsões da cota máxima mensal do Rio Acre, com antecedência de um a quatro meses, foram feitas com simulações variando de 1 até 30 neurônios na camada oculta para cada horizonte de previsão, e métricas de desempenho foram aplicadas para avaliar a eficiência do modelo. As simulações apresentaram resultados satisfatórios, com um R^2 de 0,83 e RMSE de 0,2374 para a previsão com antecedência de um mês, utilizando um modelo MLP com 25 neurônios na camada oculta.

O trabalho de Brandão, Correa e Guedes (2023) apresenta uma análise comparativa de duas abordagens de RNA para a previsão dos níveis dos rios, MLP e LSTM (do inglês Long Short-Term Memory), utilizando dados de séries temporais de quatro estações hidrológicas na bacia do Rio Madeira – que passa pelos estados de RO, MT, AM e AC. As séries temporais da cota do rio em cada uma das quatro estações contemplam registros diários entre 2001 e 2014, totalizando 20.220 registros. Diversas configurações arquiteturais foram exploradas para as MLP, enquanto as LSTM consistiam de uma única camada oculta recorrente. A métrica de desempenho adotada foi o coeficiente de determinação (R^2), que quantifica a capacidade preditiva das RNA em relação aos dados reais. O melhor desempenho foi obtido com a MLP na estação de Porto Velho, alcançando R^2 de 0,963. Os resultados indicam que, em alguns casos, as LSTM superaram as MLP, especialmente em horizontes de previsão mais curtos; porém, para períodos de previsão mais longos, não foram observadas diferenças estatisticamente significativas de desempenho.

O artigo de Zaniel *et al.* (2023) propõe um modelo híbrido que combina RNAs com o algoritmo de otimização Cuckoo Search (CS) para prever a vazão do rio na usina hidrelétrica de Terengganu, na Malásia. Utilizando dados históricos de precipitação e vazão (1971–2017) fornecidos pelo Departamento de Irrigação e Drenagem da Malásia, o estudo compara o desempenho de uma RNA tradicional com o do modelo híbrido CSRNA. A integração do Cuckoo Search visa otimizar os pesos e vieses da rede, mitigando problemas como convergência lenta e mínimos locais. Os resultados mostraram que o CS-RNA obteve desempenho superior, alcançando R^2 de 0,935 e RMSE de 10,95m³/s na fase de teste em comparação aos valores de R^2 de 0,923 e RMSE de 12,7m³/s da RNA convencional. O estudo conclui que o modelo híbrido é mais preciso e robusto.

O artigo de Souza *et al.* (2023) apresenta um estudo sobre o uso de modelos de séries temporais multivariadas para prever o nível e a vazão da água do Rio Itapemirim. Dois conjuntos de dados foram utilizados nos experimentos: (i) uma base

em que a variável alvo é o nível do rio, com 608 registros de dados de vazão de três estações fluviométricas (denominada “Vazão e Nível”), e (ii) uma base em que a variável alvo é a vazão, utilizando 15.800 registros de dados de vazão das mesmas três estações (denominada “Somente Vazão”). Os dados de nível foram coletados manualmente pela Defesa Civil, enquanto os dados de vazão foram obtidos por meio de sensores distribuídos ao longo do percurso do rio ou de seus afluentes. Modelos do tipo MLP foram otimizados utilizando a abordagem NAS para encontrar a melhor arquitetura para cada base de dados. Em ambos os casos, os dados foram divididos em 75% para treinamento e 25% para teste. A conclusão aponta que os resultados com a base “Somente Vazão” foram superiores, alcançando um R^2 de 0,955, valor semelhante ao do modelo matemático de Bof (2022), que obteve R^2 de 0,959.

O artigo de Mihel, Lerga e Kravica (2024) apresenta uma revisão sistemática dos métodos de aprendizado de máquina (ML) aplicados à previsão, reconstrução e modelagem de relações nível-vazão em rios e estuários de influência tidal. Os autores destacam que, apesar do avanço no uso de ML em ambientes de água doce, existe uma lacuna significativa no tratamento de ambientes costeiros dinâmicos, como estuários e rios tidais, onde processos complexos e não lineares prevalecem. O artigo analisa 35 estudos, divididos entre abordagens baseadas em modelos estatísticos simples, classificadores e métodos de ensemble, redes neurais rasas, redes neurais recorrentes e modelos híbridos que combinam ML com métodos físicos ou de pré-processamento de dados. As bases de dados utilizadas incluem registros horários de níveis de água, vazões, dados meteorológicos e parâmetros de maré, coletados em diferentes locais ao redor do mundo. Os resultados quantitativos variam, mas indicam que modelos híbridos superam abordagens tradicionais em termos de métricas como RMSE e R^2 , especialmente em cenários de previsão multistep e de alta complexidade. A revisão conclui que, embora redes neurais recorrentes e sistemas híbridos apresentem maior potencial para lidar com a variabilidade espaço-temporal dos processos hidrológicos, permanecem desafios como a necessidade de volumes de dados de alta resolução maiores e a dificuldade de generalização dos modelos em condições não observadas.

De modo geral, este trabalho apresenta similaridades e diferenças em relação aos estudos correlatos analisados. Assim como em Suddul *et al.* (2020) e Zaniel *et al.* (2023), foi utilizado o modelo MLP em conjunto com técnicas de otimização automática. De maneira semelhante aos estudos de Brandão, Correa e Guedes (2023) e Santos-Neto *et al.* (2021), o MLP também foi empregado como preditor principal. Em particular, o trabalho de Santos-Neto *et al.* (2021) foca na previsão do nível do Rio Acre utilizando dados climatológicos como entrada, enquanto este estudo prevê a vazão, usando dados fluviométricos. Diferentemente de Zaniel *et al.* (2023), que empregam o algoritmo de otimização Cuckoo Search, este trabalho adota uma abordagem baseada em NAS. Este artigo ainda expande o estudo de Souza *et al.* (2023), ampliando a base de dados do Rio Itapemirim, incorporando o Rio Acre e utilizando tanto RMSE quanto R^2 como métricas de avaliação. Alinhado aos artigos revisados, este trabalho adota as métricas RMSE e R^2 para avaliar o desempenho dos modelos.

Materiais e métodos

Esta seção está organizada em quatro partes: a área de estudo dos dois rios analisados, o processo de elaboração das bases de dados utilizadas nos experimentos, as métricas adotadas para avaliação dos modelos e a descrição da técnica de NAS aplicada no treinamento do modelo MLP. A Figura 2 ilustra o fluxo geral do trabalho, abrangendo a coleta e o pré-processamento das bases de dados (destacados pelo retângulo azul), o processo iterativo de seleção do melhor modelo por meio do NAS (delimitado pelo retângulo preto) e, por fim, a execução dos testes com o modelo selecionado, seguida da coleta dos resultados e métricas.

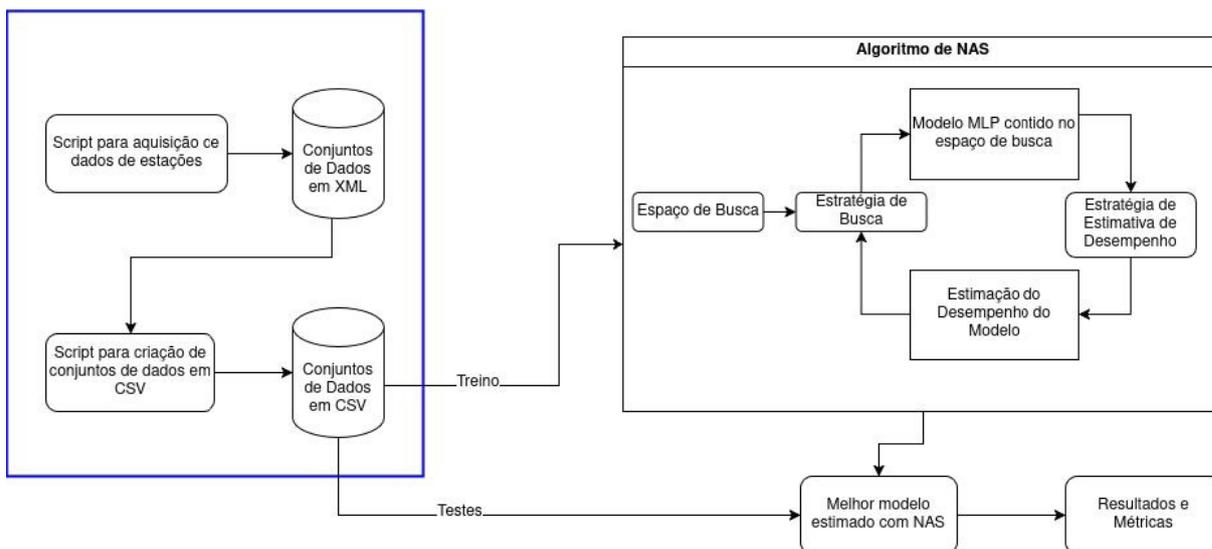


Figura 2 – Fluxograma de coleta de dados, treinamento e teste dos modelos

Fonte: Elaborado pelos(as) autores(as).

Áreas de Estudo

Esta subseção descreve as características geográficas e hidrológicas dos dois rios utilizados nos experimentos: o Rio Itapemirim e o Rio Acre. Serão apresentados dados sobre suas localizações, principais afluentes, extensão dos cursos d'água e aspectos relevantes para o contexto de previsão de vazão, complementados por mapas ilustrativos das bacias hidrográficas correspondentes.

RIO ITAPEMIRIM

O Rio Itapemirim está situado na cidade de Cachoeiro de Itapemirim, no estado do Espírito Santo, uma região historicamente afetada por episódios de alagamento (Souza; Santos, 2018). O rio é formado pela confluência de dois braços, que se unem no município de Alegre: o braço direito, que nasce em Muniz Freire, e o braço esquerdo, que nasce em Ibitirama, na Serra do Caparaó (AGERH, 2024). Seu principal afluente é o Rio Castelo, e a foz do Rio Itapemirim localiza-se no oceano Atlântico, na altura do município de Marataízes, também no Espírito Santo. A bacia hidrográfica do Rio Itapemirim ocupa uma área de aproximadamente 687.000 hectares e abrange 17 municípios.

A Figura 3 apresenta, no canto superior esquerdo, o mapa do Brasil com a localização do estado do Espírito Santo destacada em um retângulo lilás. No canto inferior esquerdo, vê-se uma ampliação desse retângulo, representando o mapa do estado. A parte direita da figura detalha a área de interesse, indicando a localização das quatro estações fluviométricas utilizadas: Francisco Gross (em amarelo), São João (em vermelho), Pacotuba (em azul) e Ilha da Luz (em lilás). A estação Ilha da Luz é a mais próxima da área urbana do município de Cachoeiro de Itapemirim, identificado pela sigla CI no mapa.

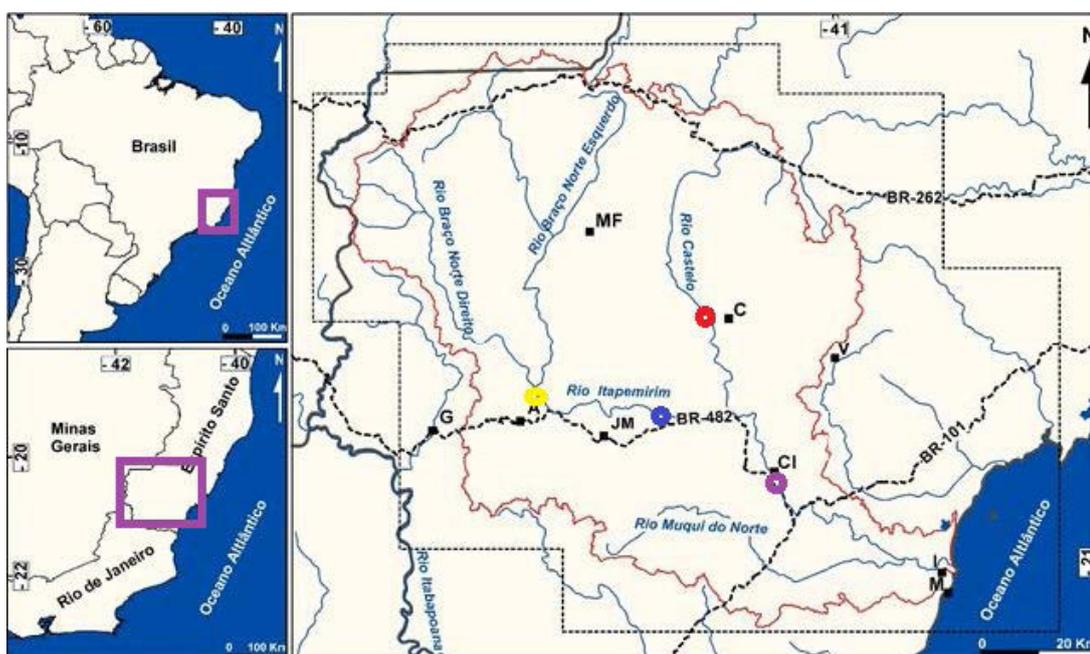


Figura 3 – Localização das estações da base de dados do Rio Itapemirim

Fonte: Adaptado de Neves *et al.* (2016).

RIO ACRE

O Rio Acre é um dos principais rios da Região Norte do Brasil e dá nome ao estado do Acre. Suas cheias já ocasionaram situações de emergência em diversos municípios ao longo de seu percurso (Monteiro; Menezes, 2024). A bacia hidrográfica do Rio Acre é formada por importantes afluentes, como o Rio Xapuri, o Riozinho do Rola e o Arroyo Bahia, além de igarapés, córregos, cursos de escoamento e esgotos urbanos (Sant'anna, 2017).

O rio nasce a uma altitude aproximada de 300 metros. Em seu curso superior, até a localidade de Seringal Paraguaçu (próxima a Assis Brasil), o Rio Acre atua como fronteira natural entre o Brasil e o Peru. Posteriormente, até a cidade de Brasileia, delimita a divisa entre o Brasil e a Bolívia. Após adentrar definitivamente no território brasileiro, o rio atravessa cidades como Porto Acre, segue pelo estado do Amazonas e deságua em sua foz. O Rio Acre percorre mais de 1.190 km desde suas nascentes até a desembocadura (IBGE, 2024).

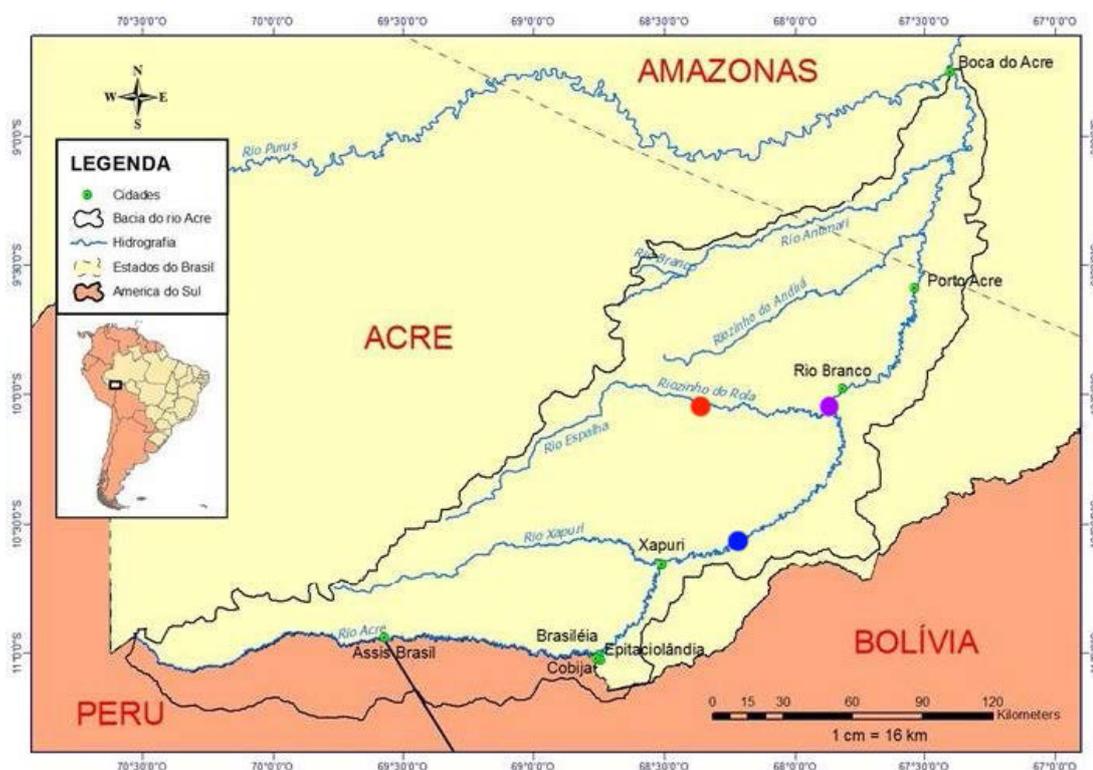


Figura 4 – Localização das estações da base de dados do Rio Acre

Fonte: Adaptado de Neto *et al.* (2017).

A Figura 4 apresenta, no retângulo localizado à esquerda, abaixo da legenda, o mapa da América do Sul com a localização do Rio Acre destacada por um retângulo preto. A ampliação dessa área, mostrada à direita, evidencia as principais estações utilizadas nos experimentos: a estação “Capixaba” (marcada em azul escuro), a estação “Rio Rola” (em vermelho) e a estação “Rio Branco” (em roxo), esta última situada próxima à área urbana da capital acreana, Rio Branco.

Bases de dados

Esta subseção apresenta os procedimentos de coleta e pré-processamento das bases de dados utilizadas nos experimentos. As fontes de dados empregadas foram o ServiceANA¹ e a plataforma HidroWEB.²

- O ServiceANA é um serviço web disponibilizado pela Agência Nacional de Águas (ANA) do Brasil, que oferece acesso a dados hidrológicos por meio de APIs. Entre as informações fornecidas, estão registros históricos sobre rios, bacias hidrográficas e estações telemétricas. Neste trabalho, utilizou-se o serviço de estações telemétricas para coletar dados de vazão das estações distribuídas ao longo dos rios estudados. Esses dados, captados automaticamente por sensores, são disponibilizados para acesso e download via API, possibilitando sua integração direta com sistemas de processamento de dados.

¹ ServiçoAna (c2025).

² Ana (c2025).

- O HidroWEB é mantido pela ANA. Trata-se de um portal que oferece acesso aos dados hidrológicos coletados por estações em todo o Brasil e em alguns países vizinhos. Além dos dados, o HidroWEB disponibiliza mapas interativos que mostram a localização de todas as estações, facilitando a visualização e seleção dos sensores mais relevantes para cada estudo. Esse recurso facilita o entendimento da distribuição geográfica dos sensores e a escolha das estações que melhor representam as condições hidrológicas dos rios estudados. Neste trabalho, o HidroWEB foi utilizado para identificar as estações mais bem posicionadas ao longo dos Rios Itapemirim e Acre.

Para a coleta de dados, foi desenvolvido um script que realiza requisições HTTP do tipo POST ao ServiceANA, retornando dados de vazão das estações selecionadas, com especificação de identificador, data de início e fim. As respostas são armazenadas em pastas específicas para cada rio. Todas as bases de dados foram construídas a partir do (i) download dos dados históricos via Webservice e (ii) execução de um script Python, que converte e concatena os arquivos, gerando um único arquivo CSV. O código está disponível no GitHub.³

Para o Rio Itapemirim, foram utilizados os dados de vazão das três estações afluentes (Francisco Gross, São João e Pacotuba) e da estação alvo, Ilha da Luz. A Tabela 1 apresenta uma amostra de cinco registros, compostos por data, hora, vazões das três estações e a vazão da estação alvo no período entre 19-02-2021 à zero hora e 01-05-2024 às 23h.

Para o Rio Acre, os dados de entrada são das estações Rio Rola e Capixaba, com a variável alvo sendo a vazão da estação Rio Branco. A Tabela 2 também apresenta cinco registros, com informações de data, hora e vazões das três estações no mesmo período de coleta. Essa base foi denominada “Rio Acre”.

Data e Hora	Francisco Gross (m ³ /s)	Pacotuba (m ³ /s)	São João (m ³ /s)	Ilha da Luz (m ³ /s)
2023-10-02 22:00:00	86,63	103,38	13,48	260,72
2023-10-02 21:00:00	88,21	107,19	13,70	265,70
2023-10-02 20:00:00	92,99	113,03	13,70	271,98
2023-10-02 19:00:00	97,83	117,01	14,15	279,60
2023-10-02 18:00:00	101,08	121,05	14,15	286,04

Tabela 1 - Amostra dos dados da base “Rio Itapemirim”
Fonte: Elaborado pelos(as) autores(as).

Data e Hora	Rio Rola (m ³ /s)	Capixaba (m ³ /s)	Rio Branco (m ³ /s)
2022-09-04 17:45:00	0,80	63,70	29,10
2022-09-04 17:30:00	0,80	63,70	28,70
2022-09-04 17:15:00	0,80	63,70	29,40
2022-09-04 17:00:00	0,80	63,70	30,50
2022-09-04 16:45:00	0,80	63,70	30,10
2022-09-04 16:30:00	0,80	63,70	30,10

Tabela 2 - Amostra dos dados da base “Rio Acre”
Fonte: Elaborado pelos(as) autores(as).

Métricas

Para avaliar o desempenho dos modelos, foram utilizadas duas métricas: o coeficiente de determinação R^2 e o RMSE (Root Mean Squared Error) (Zanial *et al.*, 2023). O coeficiente R^2 é uma medida estatística que indica a proporção da variabilidade da variável dependente (variável alvo) explicada pelas variáveis independentes (variáveis preditoras) em um modelo de regressão, conforme apresentado na Equação 1.

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (1)$$

Nesse caso, n é o número de observações, Y_i é o valor observado, \bar{Y} é a média das observações e \hat{Y}_i é o valor estimado (previsão) de Y_i . O R^2 , sendo usado para avaliar quão bem um modelo se ajusta aos dados. Seus valores variam de 0 a 1, um valor elevado (próximo de 1) sugere que o modelo é capaz de capturar grande parte da variação nos dados, enquanto valores próximos de 0 indicam baixo desempenho explicativo. De acordo com Prairie (1996), valores superiores a 0,9 são considerados indicativos de alta capacidade preditiva, enquanto valores iguais ou inferiores a 0,65 são insatisfatórios.

A métrica RMSE mede a diferença entre os valores previstos por um modelo e os valores reais de um conjunto de dados, sendo calculada como a raiz quadrada da média dos quadrados dos erros. Essa métrica quantifica a dispersão dos erros, indicando o grau de proximidade das previsões dos valores reais. Valores menores de RMSE sugerem melhor desempenho do modelo. O cálculo do RMSE é apresentado na Equação 2.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (2)$$

Sendo n é o número de observações, Y_i é o valor observado e \hat{Y}_i é o valor estimado (previsão) de Y_i . A unidade do RMSE é a mesma unidade de Y_i .

MLP Otimizado pela Técnica de NAS

Neste trabalho, adotou-se a metodologia de NAS baseada na proposta de Oliveira, Komati e Andrade (2024). Nesse estudo, os autores desenvolveram um modelo de previsão de consumo de gás em uma planta de pelletização utilizando técnicas de aprendizado de máquina (AM), com o objetivo de comparar seu desempenho em relação a métodos estatísticos tradicionais. A avaliação dos modelos foi realizada com a métrica RMSE, e os resultados indicaram que as técnicas de AM superaram os métodos estatísticos convencionais. Entre os modelos avaliados, o destaque foi o MLP otimizado por NAS, que não apenas apresentou menor erro de previsão, mas também um tempo de predição significativamente reduzido, sendo considerado o mais promissor para aplicação em ambientes de produção.

A abordagem de NAS foi implementada utilizando um algoritmo de otimização baseado na combinação de *Hill Climbing* e *greedy search* (Elsken; Metzen; Hutter, 2017). O *Hill Climbing* é um método heurístico que parte de uma solução inicial e realiza pequenas alterações, aceitando apenas as mudanças que melhoram o desempenho, até que não sejam encontradas novas melhorias. Já o *greedy search* é uma estratégia que seleciona, a cada etapa, a opção localmente mais promissora, buscando alcançar uma solução global ótima. No contexto de NAS, a combinação dessas técnicas permite explorar o espaço de arquiteturas de maneira eficiente, incrementando gradativamente a qualidade das soluções encontradas.

A Tabela 3 apresenta o conjunto de valores considerados para cada hiperparâmetro explorado. Os hiperparâmetros da arquitetura MLP analisados incluem: quantidade de neurônios na camada oculta, funções de ativação, valor de Alpha (termo de regularização), algoritmos otimizadores, taxa de aprendizado e número máximo de iterações.

Hiperparâmetros	Valores
Quantidade de neurônios na camada oculta	[10, 20, 30, 50, 100, 150, 200, 250, 300, 350, 400, 450, 500]
Função de Ativação	[identity, logistic, relu, tanh]
Alpha	[0,001, 0,0001, 0,00001, 0,000001, 0,0000001, 0.00000001]
Otimizador	[SGD, RMSprop, Adam]
Taxa de aprendizado	[0,1, 0,01, 0,001, 0,0001, 0,00001, 0,000001]
Quantidade máxima de iterações	[50, 100, 150, 200, 250, 300, 350, 400, 450, 500]

Tabela 3 - Parâmetros e valores via NAS com AutoKeras
 Fonte: Elaborado pelos(as) autores(as).

Experimentos, resultados e discussão

As bases de dados foram divididas em 75% para treino e 25% para teste, seguindo o procedimento adotado por Oliveira, Komati e Andrade (2024). O número de épocas para os experimentos foi fixado em 10. A Tabela 4 apresenta os hiperparâmetros dos melhores modelos encontrados pelo algoritmo NAS para as duas bases de dados. Observa-se que os dados do Rio Acre parecem apresentar maior complexidade, refletida na necessidade de uma arquitetura com um número significativamente maior de neurônios na camada oculta (150) em comparação ao modelo do Rio Itapemirim (10).

Hiperparâmetros	Rio Itapemirim	Rio Acre
Qtde de neurônios na camada oculta	10	150
Função de Ativação	relu	relu
Alpha	1e-08	1e-03
Otimizador	Adam	Adam
Taxa de Aprendizado	0.001	0.1
Qtde máxima de iterações	500	350

Tabela 4 - Tabela com os hiperparâmetros da arquitetura dos melhores modelos por base de dados
 Fonte: Elaborado pelos(as) autores(as).

A Tabela 5 apresenta os resultados das métricas obtidas nos conjuntos de teste. A primeira coluna identifica o rio e a referência ao artigo correspondente, a segunda coluna mostra o valor do R^2 , a terceira exibe o RMSE e a quarta informa a quantidade total de registros da base de dados. A variável alvo para o Rio Itapemirim é a vazão (m^3/s) na estação Ilha da Luz, e para o Rio Acre é a vazão (m^3/s) na estação Rio Branco.

Rio e artigo	R2	RMSE	registros
Rio Itapemirim (este artigo)	0,999	0,032	25.280
Rio Itapemirim (SOUZA <i>et al.</i> , 2023)	0,955	0,032	15.800
Rio Acre (este artigo)	0,975	92,963	40.177
Rio Acre (SANTOS-NETO <i>et al.</i> , 2021)	0,83	0,2374	552

Tabela 5 - Tabela comparativa com as métricas dos experimentos deste trabalho e trabalhos correlatos
 Fonte: Elaborado pelos(as) autores(as).

Lembrando que o estudo de Prairie (1996) indicou que valores de R^2 superiores a 0,9 podem ser considerados como representativos de alta capacidade preditiva. Observa-se que o modelo desenvolvido para o Rio Itapemirim obteve um valor de R^2 de 0,999 e um erro RMSE de apenas 0,032 m^3/s . Além disso, o R^2 de 0,999 superou o resultado obtido por Souza *et al.* (2023), cujo modelo apresentou R^2 de 0,955. A Figura 5 apresenta a curva dos dados reais de vazão do Rio Itapemirim (em metros cúbicos por segundo) em laranja, juntamente com a curva de predição em azul. As curvas são tão próximas que, em muitos trechos, a linha azul torna-se imperceptível sobre a linha laranja. Destaca-se que o modelo conseguiu prever corretamente o pico de vazão, indicado pela seta vermelha, ocorrido em março de 2024, após as fortes chuvas no estado do Espírito Santo (Oliveira, 2024).

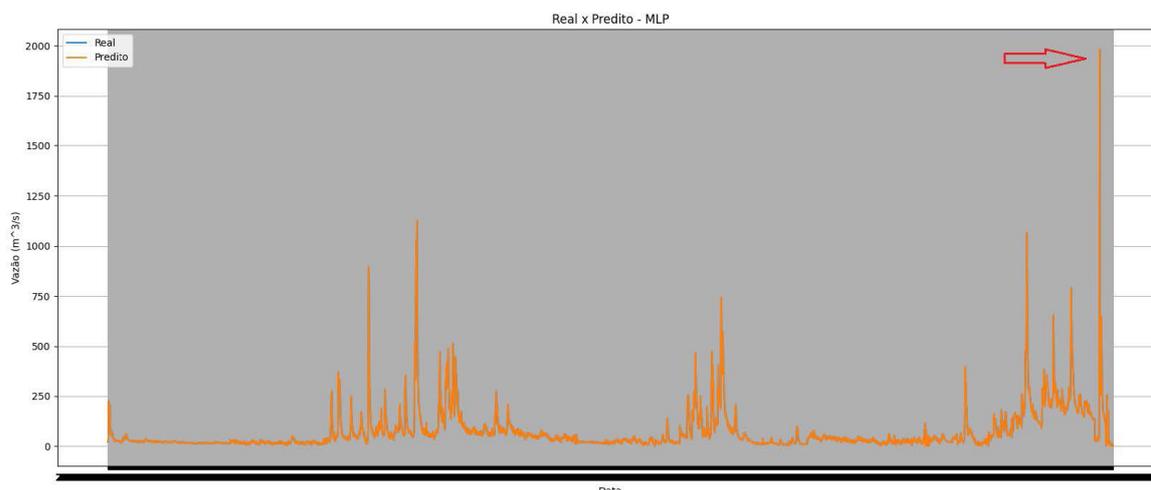


Figura 5 – Gráfico comparando a curva de dados de vazão do Rio Itapemirim e o valor predito pelo melhor modelo

Fonte: Elaborado pelos(as) autores(as).

Os valores previstos são extremamente próximos aos valores reais, o que pode ser um indicativo de possível overfitting. No entanto, esse comportamento também pode refletir o fato de que o uso de uma base de dados maior (25.280 registros em comparação aos 15.800 registros do estudo anterior) contribuiu para uma modelagem mais precisa dos dados, o que está de acordo com a literatura, que aponta a necessidade de grandes volumes de dados para que MLPs consigam generalizar adequadamente. Resultados

semelhantes são observados na literatura: o artigo de Suddul *et al.* (2020) obteve um R^2 de 0,9986 utilizando um MLP para previsão no Rio Dee, enquanto o estudo de Brandão, Correa e Guedes (2023) atingiu R^2 de 0,963 ao prever níveis do Rio Madeira no período de 2001 a 2014, utilizando uma base com 20.220 registros.

Para a base de dados Rio Acre, o melhor modelo atingiu um R^2 de 0,975 e um RMSE de 92,963 m³/s. O valor de R^2 pode ser considerado bom, indicando uma alta capacidade preditiva; entretanto, o valor do RMSE é relativamente elevado, correspondendo a aproximadamente 17% do valor médio da vazão (521 m³/s). Esse erro pode ser percebido de forma qualitativa nas curvas da Figura 6, em que a curva dos dados reais da vazão do rio em metros cúbicos por segundo é representada em laranja, e a curva da previsão em azul. Observa-se que, embora existam diferenças entre as curvas, a previsão acompanha, de maneira geral, as variações da curva real. Dois picos importantes são destacados: o primeiro, indicado pela seta vermelha, corresponde à inundação ocorrida em abril de 2023 (Rodrigues, 2023); e o segundo, indicado pela seta verde, refere-se à inundação de março de 2024 (Monteiro; Menezes, 2024).

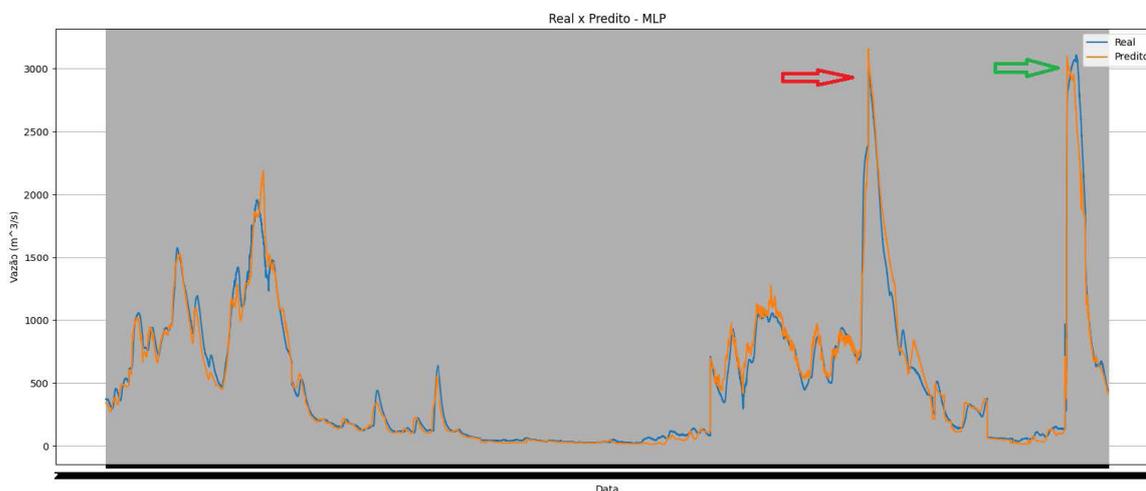


Figura 6 – Gráfico comparando a curva de dados de vazão do Rio Acre e o valor previsto pelo melhor modelo

Fonte: Elaborado pelos(as) autores(as).

O bom desempenho obtido na previsão da vazão para o Rio Itapemirim pode ser parcialmente atribuído à sua configuração hidrográfica mais simples e bem definida. O Rio Itapemirim é formado pela confluência de dois principais braços – o braço direito e o braço esquerdo. Essa formação relativamente linear e a estrutura de drenagem menos complexa favorecem a modelagem preditiva, especialmente porque foram utilizadas estações fluviométricas posicionadas estrategicamente em cada um dos braços (Francisco Gross e São João). Essa escolha de estações permite captar a maior parte da variabilidade hidrológica relevante para a previsão da vazão na área de interesse.

Em contraste, o Rio Acre apresenta características hidrológicas e geográficas mais desafiadoras. Com uma extensão superior a 1.190 km, o Rio Acre atravessa regiões de fronteira entre Brasil, Peru e Bolívia antes de adentrar definitivamente no território brasileiro. Sua bacia hidrográfica é composta por uma rede densa e complexa de afluentes, igarapés e escoamentos urbanos. Nos experimentos realizados neste trabalho, foram utilizadas apenas estações associadas aos afluentes Rio Rola e Rio Xapuri, sem cobrir toda a complexidade da bacia. Essa limitação na abrangência dos dados pode ter impactado negativamente a capacidade do modelo de capturar todas as dinâmicas hidrológicas do sistema, resultando em um erro de previsão mais elevado (RMSE de 92,963

m³/s) em comparação ao Rio Itapemirim. Essa limitação na representatividade dos dados para o Rio Acre deve ser considerada como um viés relevante nos experimentos realizados.

Conclusão

Este trabalho teve como objetivo realizar a predição da vazão de rios utilizando dados de estações fluviométricas de seus afluentes por meio de modelos MLP otimizados pela abordagem de NAS. Os resultados obtidos demonstraram que a rede neural foi capaz de capturar a complexidade e a variabilidade dos dados de vazão tanto do Rio Itapemirim quanto do Rio Acre. A adoção de técnicas de AutoML, especificamente o NAS, evidenciou a relevância da automação na busca eficiente por arquiteturas adequadas, reduzindo a necessidade de intervenção manual intensiva – um aspecto particularmente importante em aplicações dinâmicas como a previsão hidrológica.

As diferenças de desempenho observadas entre os dois rios reforçam a importância da representatividade espacial das estações na modelagem de sistemas hidrológicos, indicando que a escolha e a distribuição dos pontos de coleta têm impacto direto na qualidade das previsões. Assim, como um dos trabalhos futuros, propõe-se a ampliação das bases de dados com informações de outras estações fluviométricas, bem como a extensão da abordagem para outros rios, a fim de validar a generalização e a adaptabilidade do modelo.

Além disso, a incorporação de variáveis adicionais, como dados meteorológicos, pode enriquecer a modelagem e melhorar ainda mais a precisão das previsões. Pretende-se também investigar o uso de outros modelos, como abordagens híbridas, sugeridas por Mihel, Lerga e Krvavica (2024), explorar outras técnicas de AutoML, comparar o tempo de execução das diferentes arquiteturas e integrar a opinião de especialistas em hidrologia ou gestão de recursos hídricos.

Agradecimentos

A professora Komati agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa DT-2 (n. 302726/2023-3) e pelo projeto n. 407742/2022- 0; também agradece à Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (Fapes) pelo projeto n. 1023/2022 P:2022-8TZV6.

Referências

AGÊNCIA ESTADUAL DE RECURSOS HÍDRICOS. *Diagnóstico e Prognóstico das Condições de Uso da Água na Bacia Hidrográfica do Rio Itapemirim como Subsídio Fundamental ao Enquadramento e Plano de Recursos Hídricos*. Espírito Santo: AGERH, 2024. Disponível em: https://agerh.es.gov.br/Media/agerh/Documenta%C3%A7%C3%A3o%20CBHs/Itapemirim/RT_Levantamento_Dados_CBH%20Itapemirim.pdf. Acesso em: 1 maio 2024.

AGÊNCIA NACIONAL DAS ÁGUAS. Rede Hidrometeorológica Nacional. Brasília, DF: ANA, c2025. Disponível em: <https://www.snirh.gov.br/hidroweb/apresentacao>. Acesso em: 9 set. 2025.



ANDRADE, P. L.; SOUZA, B. M.; SOUZA, J. W. F.; PARNAÍBA, M. A. Otimização do método dos molinetes com ajuste dos perfis hidrodinâmicos para a estimação da descarga líquida em corpos hídricos por meio de técnicas de interpolação e integração numérica. *In: 31º CONGRESSO BRASILEIRO DE MATEMÁTICA (CBM), 2017, João Pessoa. Anais [...].* João Pessoa: CBM, 2017.

ASSOCIAÇÃO PRÓ-GESTÃO DAS ÁGUAS DA BACIA HIDROGRÁFICA DO RIO PARAÍBA DO SUL. *Monitoramento*. Seropédica: Agevap, 2024. Disponível em: <https://comiteguandu.org.br/monitoramento/>. Acesso em: 1 maio 2024.

BACHMANN, G.; ANAGNOSTIDIS, S.; HOFMANN, T. Scaling MLPs: A tale of inductive bias. *Advances in Neural Information Processing Systems*, [s. l.], v. 36, 2024.

BOF, L. *SARI* - Sistema de alerta do Rio Itapemirim. Espírito Santo: Agerh, 2022. Disponível em: <https://servicos.agerh.es.gov.br/sari/>. Acesso em: 10 out. 2023.

BRANDÃO, J.; CORREA, F.; GUEDES, E. A comparative analysis of artificial neural networks on river level forecasting for the Rio Madeira Basin. *In: XX ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL, 2023, Porto Alegre. Anais [...].* Porto Alegre: SBC, 2023. Disponível em: <https://sol.sbc.org.br/index.php/eniac/article/view/25699>. Acesso em: 8 set. 2025.

CONJUNTO de dados rio. Github, [s. l.], c2025. Disponível em: https://github.com/duvrxd/dataset_rio. Acesso em: 9 set. 2025.

ELSKEN, T.; METZEN, J. H.; HUTTER, F. Neural architecture search: A survey. *The Journal of Machine Learning Research*, [s. l.], v. 20, n. 1, p. 1997-2017, 2019.

ELSKEN, T.; METZEN, J.-H.; HUTTER, F. Simple and efficient architecture search for convolutional neural networks. *arXiv*, [s. l.], 2017.

FARIAS, A.; MENDONÇA, F. Riscos socioambientais de inundação urbana sob a perspectiva do sistema ambiental urbano. *Sociedade & Natureza*, Uberlândia, v. 34, n. 1, 2022.

GONZALEZ-VIDAL, A.; JIMENEZ, F.; GOMEZ-SKARMETA, A. F. A methodology for energy multivariate time series forecasting in smart buildings based on feature selection. *Energy and Buildings*, Elsevier, v. 196, p. 71-82, 2019.

HAYKIN, S. S. *Redes neurais: princípios e prática*. [S. l.: s. n.], 2001.

HUTTER, F.; KOTTHOFF, L.; VANSCHOREN, J. *Automated machine learning: methods, systems, challenges*. 1. ed. Switzerland: Springer Nature, 2019. ISBN 978-3-030-05318-5.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. *Biblioteca IBGE*. Rio Branco, AC: IBGE, 2024. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=4991>. Acesso em: 1 maio 2024.



LIMA, P.; MARQUES, F.; ORTH, S. Predição do nível de água utilizando os modelos ARIMA e Random Forest: Um estudo de caso da barragem eclusa do São Gonçalo. *In: L SEMINÁRIO INTEGRADO DE SOFTWARE E HARDWARE, 2023, Porto Alegre. Anais [...].* Porto Alegre: SBC, 2023. ISSN 2595-6205. Disponível em: <https://sol.sbc.org.br/index.php/semish/article/view/25059>. Acesso em: 8 set. 2025.

MIHEL, A. M.; LERGA, J.; KRVAVICA, N. Estimating water levels and discharges in tidal rivers and estuaries: Review of machine learning approaches. *Environmental modelling & software*, Elsevier, p. 106033, 2024.

MIKKULAINEN, R.; LIANG, J.; MEYERSON, E.; RAWAL, A.; FINK, D.; FRANCON, O.; RAJU, B.; SHAHRZAD, H.; NAVRUZYAN, A.; DUFFY, N. Evolving deep neural networks. *In: ARTIFICIAL Intelligence in the Age of Neural Networks and Brain Computing*. 1. ed. United Kingdom: Elsevier, 2019. p. 293-312. ISBN 9780128162507.

MONTEIRO, H.; MENEZES, R. Mais de 11 mil pessoas estão fora de casa por enchente no AC e governo federal reconhece emergência. *Gl Globo*, [s. l.], 2024. Disponível em: <https://g1.globo.com/ac/acre/noticia/2024/02/26/mais-de-11-mil-pessoassaoafetadaspor-enchente-no-ac-e-governo-federal-reconhece/-situacaodeemergencia.ghtml>. Acesso em: 1 maio 2024.

MORETTIN, P. A.; TOLOI, C. M. Análise de séries temporais – Vol. 1: modelos lineares univariados. 3. ed. São Paulo: Editora Blucher, 2018. 474 p.

NETO, L. S.; MANIESI, V.; SILVA, M. J.; SILVA, D.; QUERINO, C.; REIS, V. Análise da precipitação mensal e pentadal durante a cheia de 2015 no Rio Acre usando o produto 3B43 do TRMM. *In: VII SIMPÓSIO INTERNACIONAL DE CLIMATOLOGIA, 2017, Petrópolis. Anais [...].* Petrópolis: [S. n.], 2017.

NEVES, M. A. N.; MIRANDA, R. F.; TRIGO, M. S.; OLIVEIRA, M. S. M.; PESSOA, A. D.; MANCINI, L. H. Assinatura isotópica das águas pluviais e subterrâneas na bacia hidrográfica do Rio Itapemirim, estado do Espírito Santo. *Revista Águas Subterrâneas*, Belo Horizonte, 2016. Disponível em: <https://aguassubterraneas.abas.org/asubterraneas/article/view/28688>. Acesso em: 8 set. 2025.

OLIVEIRA, S. Rio Itapemirim sobe com velocidade e prefeitura de Cachoeiro faz alerta. *A Gazeta*, [s. l.], 2024. Disponível em: <https://www.agazeta.com.br/agora/rioitapemirim-sobe-com-velocidade-e-prefeitura-decachoeiro-faz-alerta-0324>. Acesso em: 1 maio 2024.

OLIVEIRA, V. M.; KOMATI, K. S.; ANDRADE, J. O. Implementing neuroevolution for gas consumption forecasting in the steel industry. *In: 2024 L Latin American Computer Conference (CLEI)*. [S. l.: s. n.], 2024. p. 1-10.

OLIVEIRA, V. M.; KOMATI, K. S.; ANDRADE, J. O. Seleção de características de séries temporais multivariadas do consumo de gás na pelotização de minério de ferro. *In: XXVIII SIMPÓSIO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO, 2021, Rio de Janeiro. Anais [...].* Rio de Janeiro: Unesp, 2021.

PARK, Y.-S.; LEK, S. Artificial neural networks: Multilayer perceptron for ecological modeling. *In: DEVELOPMENTS in environmental modelling*. [S. l.]: Elsevier, 2016, v. 28, p. 123-140.

PRAIRIE, Y. T. Evaluating the predictive power of regression models. *Canadian Journal of Fisheries and Aquatic Sciences*, Canada, v. 53, n. 3, p. 490-492, 1996.

RODRIGUES, I. Sobe para 56 mil o número de moradores atingidos pela enchente do Rio Acre, aponta Defesa Civil. *G1 Globo*, Acre, 2023. Disponível em: <https://g1.globo.com/ac/acre/noticia/2023/04/01/sobe-para-56-mil-o-numerodemoradores-atingidos-pela-enchente-do-rio-acre-aponta-defesa-civil.ghtml>. Acesso em: 1 maio 2024.

SAITO, S. M.; DIAS, M. C. A.; ALVALÁ, R. C. S.; STENNER, C.; FRANCO, C. O.; RIBEIRO, J. V. M.; SOUZA, P. A. d.; SANTANA, R. A. S. d. M. População urbana exposta aos riscos de deslizamentos, inundações e enxurradas no Brasil. *Sociedade & Natureza*, Uberlândia, v. 31, p. e46320, 2023.

SANT'ANNA, F. M. Bacia do rio Acre: a formação de uma governança transnacional. *In: GOVERNANÇA multiescalar dos recursos hídricos transfronteiriços na Amazônia*. São Paulo: Editora Unesp, 2017. p. 199-269. ISBN 978-85-9546-180-2.

SANTOS-NETO, L. A.; MANIESI, V.; QUERINO, C. A. S.; SILVA, M. J. G.; BROWN, V. R. Modelagem hidroclimatológica utilizando redes neurais multi layer perceptron em bacia hidrográfica no sudoeste da amazônia. *Revista Brasileira de Climatologia*, Paraná, v. 26, 2021. Disponível em: <https://ojs.ufgd.edu.br/index.php/rbclima/article/view/14238>. Acesso em: 8 set. 2025.

SERVICEANA. Página Principal. [S. l.], c2025. Disponível em: <https://telemetriaws1.ana.gov.br/ServiceANA.aspx>. Acesso em: 9 set. 2025.

SOUZA, A. C. D.; SANTOS, C. T. Identificação dos problemas de alagamento na cidade de Cachoeiro de Itapemirim-ES: estudo de caso sobre a área central. *In: 16º CONGRESSO BRASILEIRO DE GEOLOGIA DE ENGENHARIA E AMBIENTAL*, 2018, São Paulo. *Anais [...]*. São Paulo: CBGE, 2018.

SOUZA, E.; OLIVEIRA, V.; ANDRADE, J.; KOMATI, K. Previsão de nível e vazão de água de um rio usando rede perceptron multi-camada: um estudo de caso do Rio Itapemirim. *In: XI ESCOLA REGIONAL DE INFORMÁTICA DE GOIÁS*, 2023, Porto Alegre. *Anais [...]*. Porto Alegre: SBC, 2023. Disponível em: <https://sol.sbc.org.br/index.php/erigo/article/view/27244>. Acesso em: 8 set. 2025.

SUDDUL, G.; DOOKHITRAM, K.; BEKAROO, G.; SHANKHUR, N. An evolutionary multilayer perceptron algorithm for real time river flood prediction. *In: IEEE. Zooming innovation in consumer technologies conference (ZINC)*. [S. l.]: IEEE, 2020. p. 109-112.



TELIKANI, A.; TAHMASSEBI, A.; BANZHAF, W.; GANDOMI, A. H. Evolutionary machine learning: *A survey*. *ACM Comput. Surv., Association for Computing Machinery*, New York, USA, v. 54, n. 8, 2021. ISSN 0360-0300. Disponível em: <https://doi.org/10.1145/3467477>. Acesso em: 8 set. 2025.

ZANIAL, W. N. C. W.; MALEK, M. B. A.; REBA, M. N. M.; ZAINI, N.; AHMED, A. N.; SHERIF, M.; ELSHAFIE, A. River flow prediction based on improved machine learning method: Cuckoo search-artificial neural network. *Applied Water Science*, Springer, v. 13, n. 1, p. 28, 2023.

ZOPH, B.; LE, Q. V. Neural architecture search with reinforcement learning. *arXiv*, [s. l.], 2016.