

Avaliação das Redes Neurais Artificiais no Processo de Estimação dos Valores de Vazão Natural do Aproveitamento Hidrelétrico de Porto Primavera

Prof. Dr. Leandro Augusto da Silva Me. Cavour Martinelli Neto

29 de fevereiro de 2024

Resumo

A pesquisa realizada avaliou o desempenho dos algoritmos de aprendizagem de máquina para auxiliar a operação Usina Hidrelétrica de Itaipu. Para isso, foi estimada a vazão em função do tempo do aproveitamento hidrelétrico de Porto Primavera, localizado na bacia do Rio Paraná. A aprendizagem de máquina foi utilizada como alternativa aos modelos numéricos baseados na transferência de massa e no balanço energético. Os modelos numéricos utilizam equações que dependem de longas séries temporais de dados meteorológicos e hidrológicos, os quais nem sempre estão disponíveis. Por outro lado, os avanços tecnológicos relacionados aos recursos computacionais e à Inteligência Artificial podem contribuir para aperfeiçoá-los. As Redes Neurais Artificiais (RNA) foram capazes de detectar padrões específicos no comportamento da vazão de água ao longo do tempo e realizar previsões para auxiliar a operação de Usinas Hidrelétricas. Os tipos memória longa de curto prazo (LSTM) e *Gated Recurrent Unit* (GRU) apresentaram os melhores resultados para estimar os valores de vazão em um e nove dias, respectivamente. Os valores do Erro Absoluto Médio (EAM) e do Erro Percentual Absoluto Médio (EPAM) foram de 105,20 m³/s e 2,02% para um e de 527,00 m³/s e 9,26% para nove dias de previsão.

Palavras-chaves: Aprendizagem de Máquina. Inteligência Artificial. Redes Neurais Artificiais. Sistemas de Gestão da Água.

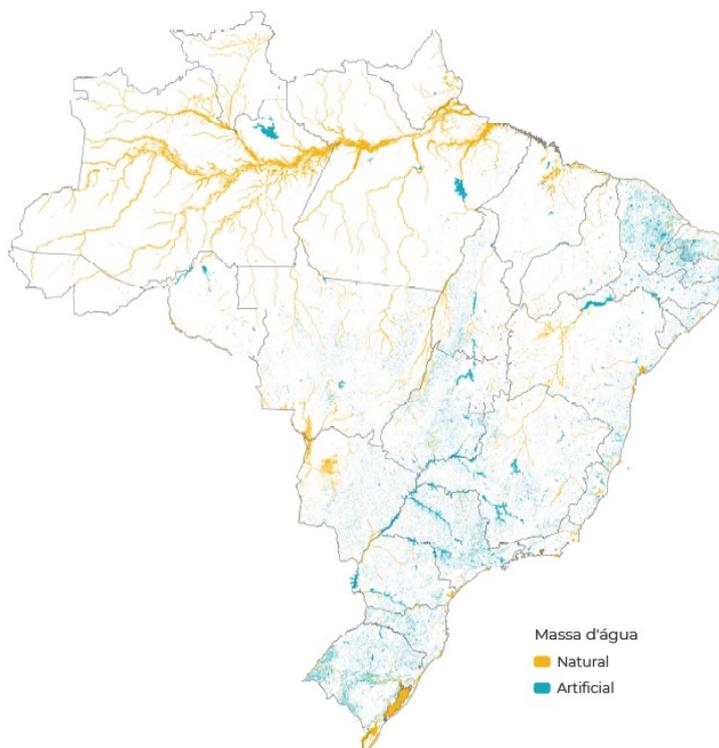
1 Introdução

O mundo enfrenta uma escassez de recursos e a água é o mais importante e responsável pela vida em nosso planeta. Entre os anos de 2013 a 2015 a região Sudeste passou por uma de suas piores crises hídricas já registradas (MARENGO et al., 2015). É sabido que a água é um recurso renovável, porém o crescimento populacional e o crescente uso deste recurso em diversos setores da economia, associado a problemas de gestão e infraestrutura nos processos de tratamento e distribuição limitam seu uso. Segundo estimativas da ONU, mais de 2 bilhões de pessoas vivem em países que enfrentam

estresse hídrico (ONU, 2023). Outro dado importante e que representa preocupação é o esgotamento das reservas subterrâneas de água. A agricultura é responsável pela maior parcela do consumo de água (72%), seguido da indústria (16%) e dos municípios (12%). Segundo a ONU, tanto a demanda de água como a demanda por alimentos tende a aumentar 50% nos próximos 30 anos (FAO, 2022). A escassez de água pode ser atribuída ao aumento populacional, crescimento da indústria e distribuição desigual (JAN et al., 2022). Ações antropogênicas como o represamento e a construção de barragens têm como objetivo o uso da água para garantir o abastecimento público, fornecer água para os setores industrial e agropecuário, gerar energia elétrica, acumular rejeitos (ex.: mineração), proteger o ecossistema e oferecer opções de lazer. No entanto, estas intervenções podem resultar no comprometimento dos lençóis d'água, no aumento da perda de água por evaporação e em mudanças na sua temperatura causada pela alteração da vazão natural dos rios. Como consequência, os processos físicos e biogeoquímicos em rios, o ecossistema e a qualidade da água são comprometidos (ANA, 2021).

O Brasil possui mais de 240 mil massas d'água inventariadas pela Agência Nacional de Águas e Saneamento Básico (ANA), ocupando uma área de 174.000 km² (ANA, 2021). As massas d'água naturais representam a maior parte (73,8%) em comparação com as artificiais (27,6%). Por outro lado, as massas d'água artificiais superam em número as naturais. A figura 1 ilustra a distribuição das massas d'água que compõem o território brasileiro. Nela, é possível observar que as massas d'água naturais são representadas pelos

Figura 1 – Distribuição das massas d'água no Brasil



Fonte: ANA (2020a)

rios e seus afluentes localizados, em sua maioria, na região Amazônica e no Pantanal e ocupam uma área de, aproximadamente, 128 mil km². As massas d'água artificiais ocupam uma área menor (aproximadamente 46 mil km²) e representam reservatórios operados

pelo Operador Nacional do Sistema (ONS) para a geração de energia elétrica, para o abastecimento urbano e em atividades essenciais como a agricultura e a aquicultura. Por este motivo, estão localizados em regiões semiáridas (região Nordeste) ou com maior concentração populacional (regiões Sul e Sudeste). O estudo aqui apresentado tem como principal motivação a importância dos papéis social e econômico dos reservatórios de água naturais e artificiais presentes no território brasileiro.

Os aspectos que justificam este estudo estão embasados na importância dos reservatórios naturais e artificiais de água para o abastecimento urbano, geração energia, fornecimento de água para os setores industrial e agropecuário, proteção do ecossistema e como opção de lazer. Outro ponto é que os métodos numéricos utilizados para criar modelos representativos do comportamento dos reservatórios de água exigem a disponibilidade de séries temporais de variáveis climáticas como umidade absoluta da atmosfera, velocidade do vento, radiação solar, índice de precipitação, entre outros, o que em muitos casos, não acontece (JAN et al., 2022). Além disso, o setor de geração de energia elétrica assume uma posição de destaque. O relatório síntese do Balanço Energético Nacional (BEN) de 2023 apontou que mais de 85% da matriz energética brasileira é originária de fontes renováveis, sendo que a geração hidráulica contribui com mais de 70% deste total (CNI, 2021). Isso significa que eventos climáticos extremos que afetem o nível dos reservatórios de água têm como consequência o acionamento de fontes alternativas e mais caras para gerar energia elétrica. Desta forma, esta pesquisa busca deferir se os avanços tecnológicos como o aumento do poder de processamento dos computadores e os algoritmos de aprendizagem de máquina permitem ou não a criação de modelos para prever a vazão da água de reservatórios e sistemas fluviais em função do tempo (séries temporais).

2 Referencial Teórico

2.1 Modelos Numéricos

Existem diferentes modelos baseados em processos (modelos numéricos) utilizados para prever o comportamento dinâmico de lagos e reservatórios de água. Um destes modelos é o *General Lake Model* (GLM). Trata-se de um modelo unidimensional embasado nas leis da transferência de massa e no balanço energético, este último, essencial para prever os valores de temperatura da água. O modelo GLM apresenta vantagens, pois possui código aberto e possibilita a integração com outros modelos representativos de processos biogeoquímicos (READ et al., 2019). O balanço energético do modelo GLM leva em consideração parâmetros como a incidência de radiação de ondas curtas, fluxos de calor sensível e latente, a incidência de radiação de ondas longas e a radiação de ondas longas emitida a partir do corpo d'água (Equação 1). A diferença entre os valores de temperatura das águas superficiais e mais profundas cria um perfil característico chamado de estratificação térmica que influencia a concentração de oxigênio, nutrientes e plâncton. Os dados meteorológicos influenciam o modelo GLM e, dependendo da fonte de dados consultada, podem conter imprecisões. Este problema é menor quando sensores são utilizados para realizar medições in loco (READ et al., 2019).

$$c_w \rho_s z_s \frac{dT_s}{dt} = \phi SW_s - \phi E + \phi H + \phi LW_{in} - \phi LW_{out} \quad (1)$$

onde,

c_w é o calor específico da água;

ρ_s a densidade específica da água na superfície;

z_s a profundidade;
 T_s a temperatura superficial da água;
 ϕSW_s a incidência de radiação de ondas curtas;
 ϕE o fluxo de calor latente;
 ϕH o fluxo de calor sensível;
 ϕLW_{in} a incidência de radiação de ondas longas; e
 ϕLW_{out} a radiação de ondas longas emitida a partir do corpo d'água;

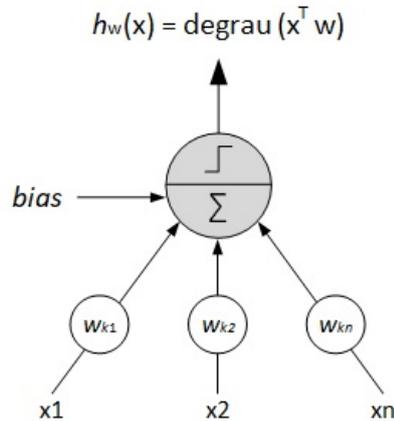
Outro exemplo de modelo baseado em processo é o *Hydraulic Modeling* (Modelagem Hidráulica). Baseado nas leis físicas da conservação da massa e momento, a versão 1.0 deste modelo representa o comportamento de uma rede de distribuição de água. No entanto, a representação teórica de eventos ainda não totalmente compreendidos como rachaduras, desgastes e acúmulo de biofilme é complexa. Nestes casos, os modelos orientados por dados podem contribuir com os modelos teóricos para a criação do que é conhecido como gêmeo digital. Desta união, surgiu o *Hydraulic Modeling 2.0* (JENNY et al., 2020). Já o modelo *Air2water* é um modelo híbrido físico-estatístico que utiliza as equações do balanço energético para prever a temperatura das águas superficiais em lagos, levando em consideração somente a temperatura do ar. No entanto, os fatores climáticos e o tempo também influenciam as variações na temperatura da água, tornando as previsões mais complexas. Em contrapartida, os modelos de aprendizagem de máquina procuram estabelecer relações entre estes fatores e a variável de interesse, fazendo com que, normalmente, apresentem métricas de desempenho superiores ao modelo *Air2water* (HAO et al., 2023). Além da contribuição com os modelos baseados em processos, os modelos orientados por dados podem ser usados como ferramenta de simulação de cenários críticos para que haja um planejamento antecipado dos processos de intervenção. Eles não substituem a Modelagem Hidráulica, mas têm apresentado melhores resultados para, por exemplo, detectar perdas e prever a demanda de água com base em um perfil de consumo (JENNY et al., 2020).

2.2 Redes Neurais Artificiais

O conceito de Redes Neurais Artificiais (RNA) surgiu no início da década de 1940 com Warren McCulloch e Walter Pitts (HAYKIN, 2001; AURÉLIEN, 2021). Em 1958, Rosenblatt introduziu um modelo de rede neural chamado *perceptron* (ROSENBLATT, 1958). Esta rede neural artificial é composta por um sinal de entrada representado por $x_1, x_2 \dots x_n$, pesos $w_{K1}, w_{K2} \dots w_{Kn}$, uma função de ativação, um viés (bias) e uma saída. A figura 2 ilustra a estrutura de uma rede neural artificial do tipo *perceptron*, considerando uma função de ativação do tipo degrau. A *perceptron* garante a convergência para uma solução, contanto que seja possível a separação linear de suas entradas (CASTRO; FERRAI, 2016; HAYKIN, 2001). Quando há ao menos uma camada intermediária, a rede neural é chamada de perceptron multicamadas ou do inglês *Multi-Layer Perceptron* (MLP). O objetivo com este tipo de arquitetura é a resolução de problemas mais complexos, os quais não podem ser resolvidos com a *perceptron*. O número de neurônios na camada de entrada varia conforme a quantidade de variáveis independentes. O número de camadas intermediárias e de neurônios em cada uma delas, a função de ativação, o número de neurônios na camada de saída e a função de ativação na camada de saída são alguns dos parâmetros ajustáveis de uma rede neural artificial e dependerão do tipo de tarefa (classificação ou regressão) que se deseja realizar (AURÉLIEN, 2021). Um dos algoritmos utilizados para treinar uma RNA é chamado de retropropagação. Seu funcionamento consiste em passagens para frente e para trás. Depois de receber as instâncias na camada de entrada, o algoritmo calcula as saídas depois de cada camada oculta e até a camada de

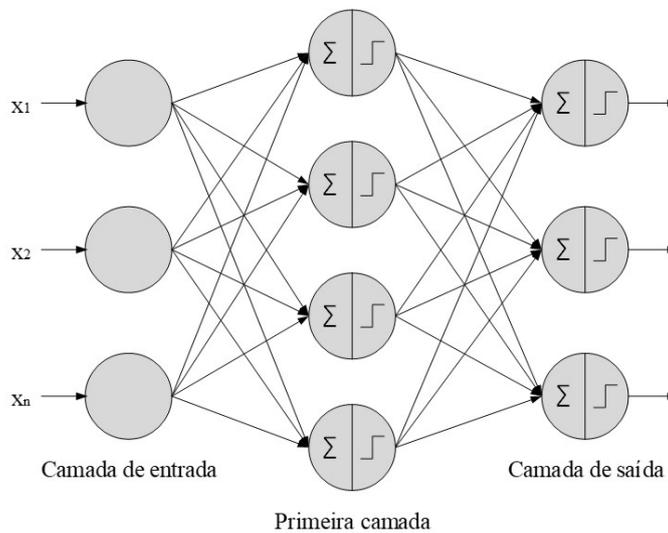
saída da rede (passagem para frente). Em seguida, o algoritmo realiza a passagem para trás e calcula a contribuição de cada uma das conexões no erro obtido, resultado da comparação entre os valores reais e estimados. Finalmente, os pesos são ajustados para minimizar o erro observado. A figura 3 ilustra um exemplo de uma rede neural artificial perceptron multicamadas.

Figura 2 – Estrutura de um neurônio artificial



Fonte: Elaborado pelo autor

Figura 3 – Estrutura de uma rede neural artificial perceptron multicamadas

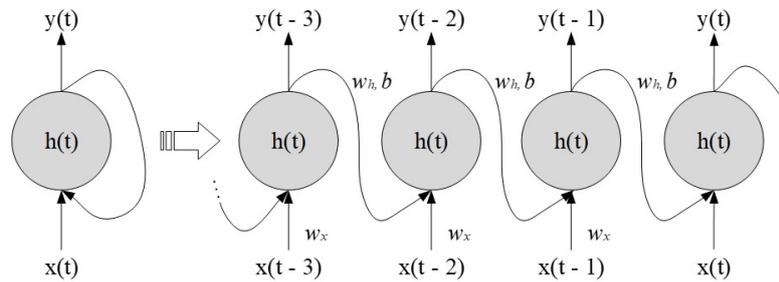


Fonte: Elaborada pelo autor

As Redes Neurais Recorrentes (RNR) são uma variante das redes neurais artificiais que recebem um sinal de entrada $x(t)$, geram uma saída $y(t)$ e a enviam de volta para a entrada, ou seja, agora esta saída representa o estado anterior (AURÉLIEN, 2021). Por serem capazes de estabelecer relações não lineares entre os dados de entrada e saída, as redes neurais recorrentes são utilizadas para o processamento de sequências com aplicações práticas nos campos do reconhecimento de fala, tradução automática, previsão dos valores de ações no mercado financeiro, entre outras (AURÉLIEN, 2021). Da figura 4, para um instante de tempo t , o estado oculto $h(t)$ representa a saída $y(t)$ e é, ao mesmo tempo,

uma entrada para o instante de tempo subsequente $x(t + 1)$. O estado oculto é dado pela equação 2. Por serem consideradas redes profundas, as redes neurais recorrentes podem apresentar problemas de instabilidade dos gradientes e de memória de curto prazo. Isto quer dizer que, conforme os dados de entrada fluem através de suas camadas, as informações iniciais podem ser perdidas. Uma forma de resolver estes problemas é a utilização de células que retêm informações de longo prazo como, por exemplo, as células memória longa de curto prazo ou do inglês *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU). Em comparação com uma rede neural recorrente simples, a célula LSTM demanda maior poder computacional (TRAN et al., 2021). A célula LSTM surgiu no ano de 1997 e foi desenvolvida por Sepp Hochreiter e Jürgen Schmidhuber (HOCHREITER; SCHMIDHUBER, 1997). Trata-se de uma célula de memória, cuja principal vantagem é detectar relações de longo prazo. Ela possui quatro camadas totalmente conectadas, sendo que uma delas (camada principal) está presente em toda célula básica de uma rede neural recorrente. A camada principal $g(t)$ avalia o sinal de entrada $x(t)$ e o estado anterior $h(t - 1)$ e grava as informações mais importantes no estado de longo prazo $c(t)$. Este procedimento é controlado pela porta de entrada $i(t)$. A porta de esquecimento $f(t)$ é responsável por eliminar parte das informações do estado de longo prazo $c(t - 1)$. Finalmente, a porta de saída $o(t)$ seleciona quais informações do estado de longo prazo $c(t - 1)$ devem ser geradas para $h(t)$ e para a saída $y(t)$ (Figura 5).

Figura 4 – Estrutura de uma rede neural recorrente

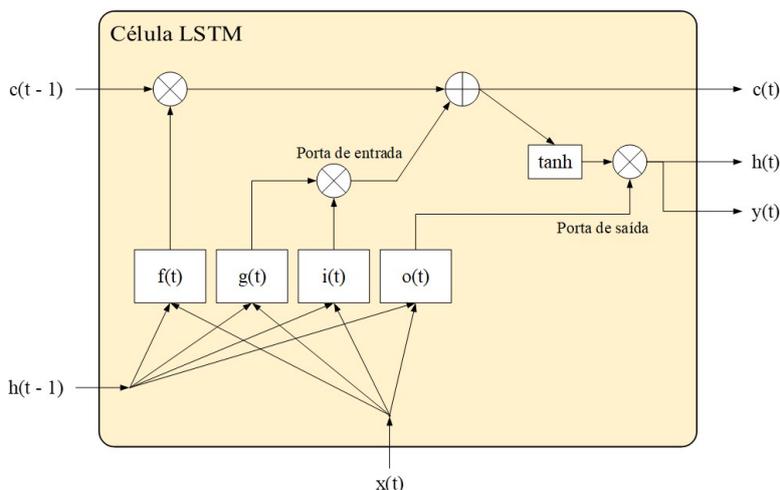


Fonte: Elaborada pelo autor

$$h(t) = f(w_x x(t) + w_h h(t) + b) \quad (2)$$

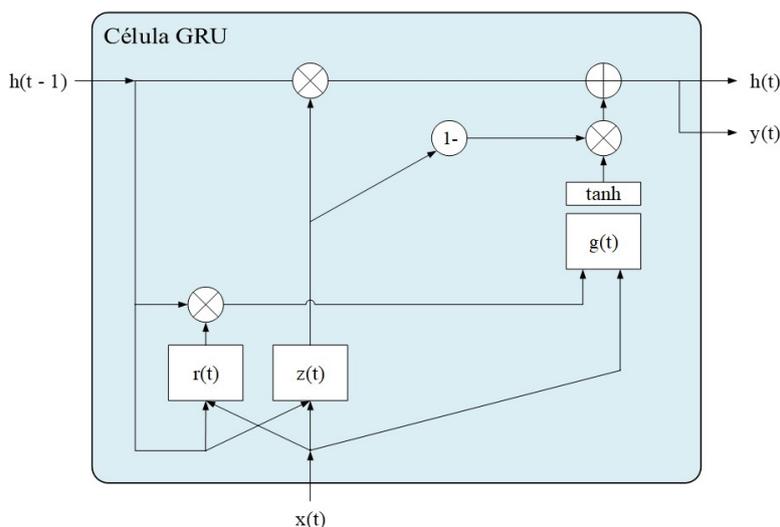
A célula *Gated Recurrent Unit* (GRU) é uma variante da célula LSTM (Figura 6). Primeiramente, os estados de curto e longo prazo são armazenados em um único vetor $h(t)$. Além disso, apenas a porta $z(t)$ controla as portas de entrada e esquecimento. O vetor de saída combina os estados anterior e atual em um único vetor. A porta de controle $r(t)$ seleciona qual parte da informação do estado anterior $h(t - 1)$ será passada para a camada principal $g(t)$. As redes neurais têm sido amplamente utilizadas para o processamento de sequências. Alguns estudos demonstraram que o desempenho das redes neurais em comparação com outros modelos de aprendizagem de máquina como, por exemplo, florestas aleatórias e máquina de vetores de suporte foi melhor. A assertividade das previsões realizadas pelas redes neurais artificiais depende do ajuste de seus hiperparâmetros, porém como não há uma regra para a escolha do número de camadas ocultas, quantidade de neurônios por camada, taxa de aprendizagem, inicialização dos pesos e demais hiperparâmetros, muitos dos trabalhos conduzidos optam pela tentativa e erro ou por algoritmos evolutivos (TRAN et al., 2021).

Figura 5 – Célula do tipo memória longa de curto prazo (LSTM)



Fonte: Elaborada pelo autor

Figura 6 – Célula do tipo *Gated Recurrent Unit* (GRU)



Fonte: Elaborada pelo autor

2.3 Métricas de Desempenho

O processo de treinamento dos modelos de aprendizagem de máquina busca minimizar o erro de predição, ou seja, a diferença entre os valores reais e os valores estimados. As métricas utilizadas para avaliar o desempenho dos modelos serão o coeficiente de determinação (R^2), o Erro Absoluto Médio (EAM), o Erro Percentual Absoluto Médio (EPAM), o Erro Quadrático Médio (EQM) e a Raiz do Erro Quadrático Médio (REQM). O coeficiente de determinação (R^2) descreve a relação entre os valores reais e previstos em relação à média, ou seja, é a variância em porcentagem do rótulo que pode ser explicada pelas variáveis independentes (atributos) do modelo. Para modelos não lineares, um valor negativo de R^2 representa um modelo que se ajusta mal aos dados (PLEVRIS et al., 2022) e um valor próximo de um indica conformidade entre os valores reais e previstos. O erro absoluto é dado pelo módulo da diferença entre o valor real e o valor previsto. Portanto, o

Erro Absoluto Médio (EAM) é representado pela soma dos erros absolutos dividido pelo número total de instâncias (AGRAWAL, 2021). Quanto maior o erro absoluto, maior será o quadrado deste erro e esta é a função do Erro Quadrático Médio (EQM) e da Raiz do Erro Quadrático Médio (REQM), ou seja, sobrepunhar as maiores diferenças entre os valores reais e previstos (CASTRO; FERRAI, 2016). As equações 3, 4, 5, 6 e 7 representam as medidas de desempenho descritas.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$EPAM = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (5)$$

$$EQM = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2 \quad (6)$$

$$REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2} \quad (7)$$

onde,

y é o valor real ou desejado;

\hat{y} o valor previsto pelo modelo;

\bar{y} a média dos valores reais ou desejados;

$\hat{\bar{y}}$ a média dos valores previstos pelo modelo; e

n o número total de instâncias;

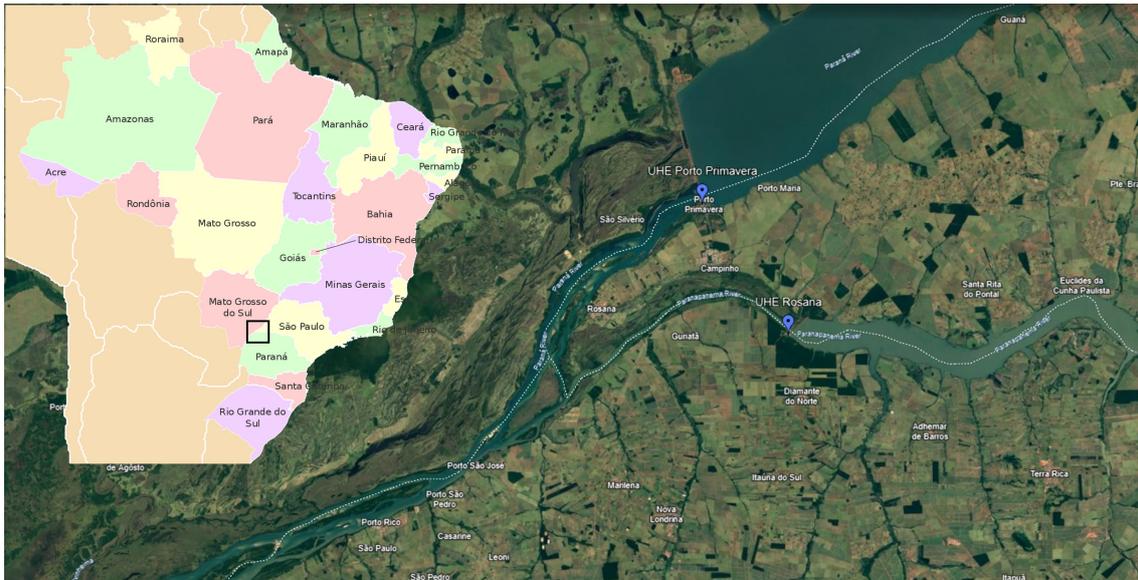
3 Métodos

3.1 Local e dados de estudo

O desempenho das redes neurais artificiais foi avaliado para uma base de dados real que registra os valores médios diários de vazão natural em m³/s do aproveitamento (posto) hidrelétrico de Porto Primavera localizado na bacia do rio Paraná. A série histórica de vazões compreende o período de 01/01/1931 a 31/12/2021 e está disponível no site do Operador Nacional do Sistema (ONS). Em 23 de fevereiro de 1999, neste mesmo local, entrou em operação a Usina Hidrelétrica (UHE) Engenheiro Sérgio Motta (Porto Primavera). Ela conta com 14 unidades geradoras com capacidade instalada de 1540 MW de potência. Além de gerar energia, os trabalhos realizados pela Usina Hidrelétrica de Porto Primavera em conjunto com a Reserva Particular do Patrimônio Natural Cisalpina (RPPN) visam a preservação de mais de 3800 hectares de área natural que abrigam mais de 250 espécies da fauna nativa da região (CESP, 2023). O rio Paraná faz parte da vasta rede hidrográfica que banha a região do Pontal do Paranapanema localizada no extremo oeste do estado de São Paulo, na região sudeste do Brasil (Figura 7). Esta área compreende 32

municípios com uma população de, aproximadamente, 4.639.899 habitantes. As principais atividades econômicas estão concentradas no setor de serviços e o turismo é favorecido devido à formação de lagos e ao represamento dos rios Paraná e Paranapanema (GAMBA et al., 2022). A Usina Hidrelétrica de Porto Primavera possui um reservatório com 2250 km² de área e a mais extensa barragem do Brasil com, aproximadamente, 10,2 km de comprimento (Figura 8).

Figura 7 – Localização da UHE Engenheiro Sérgio Motta (Porto Primavera)



Fonte: Elaborada pelo autor

Figura 8 – Usina Hidrelétrica Engenheiro Sérgio Motta

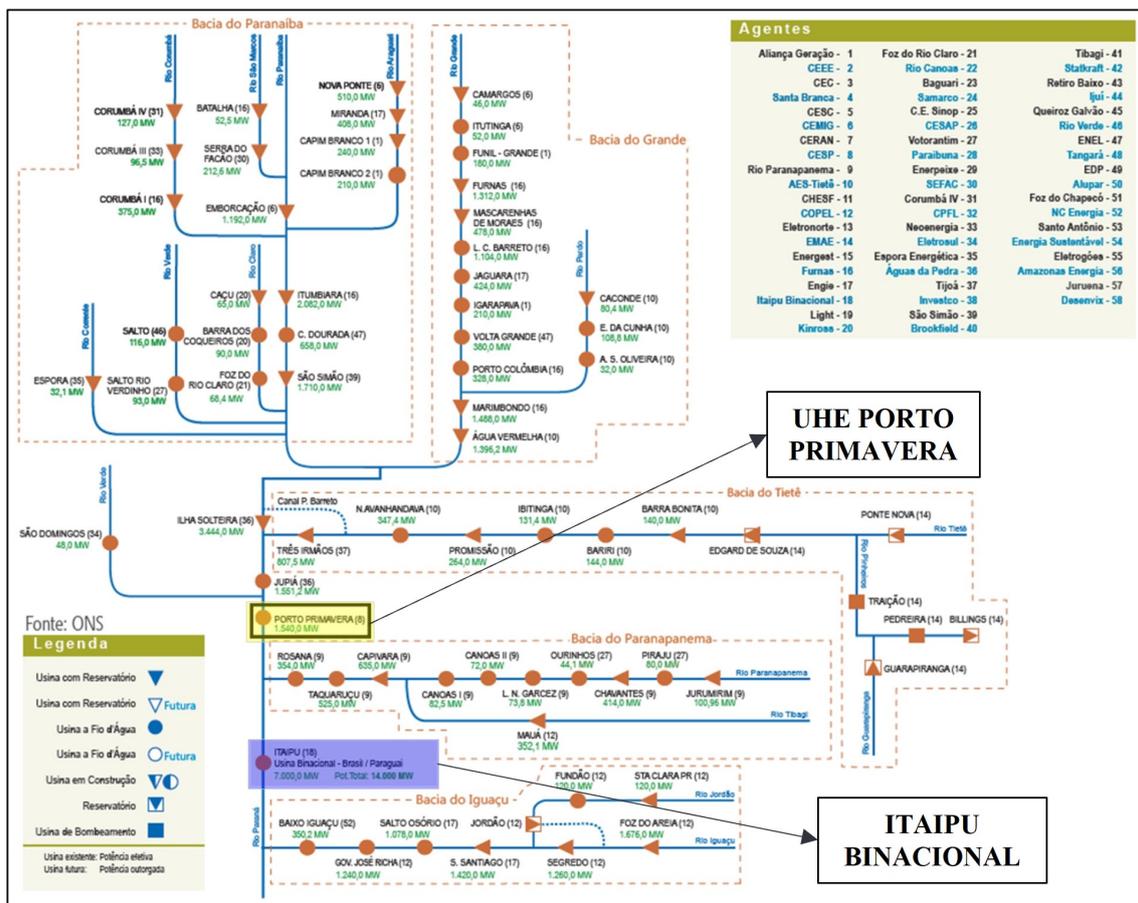


Fonte: <<https://www.rosana.sp.gov.br/>>

Com base em uma entrevista realizada com especialistas, a Usina Hidrelétrica de Porto Primavera está localizada a montante da Usina Hidrelétrica de Itaipu (Figura 9). Os

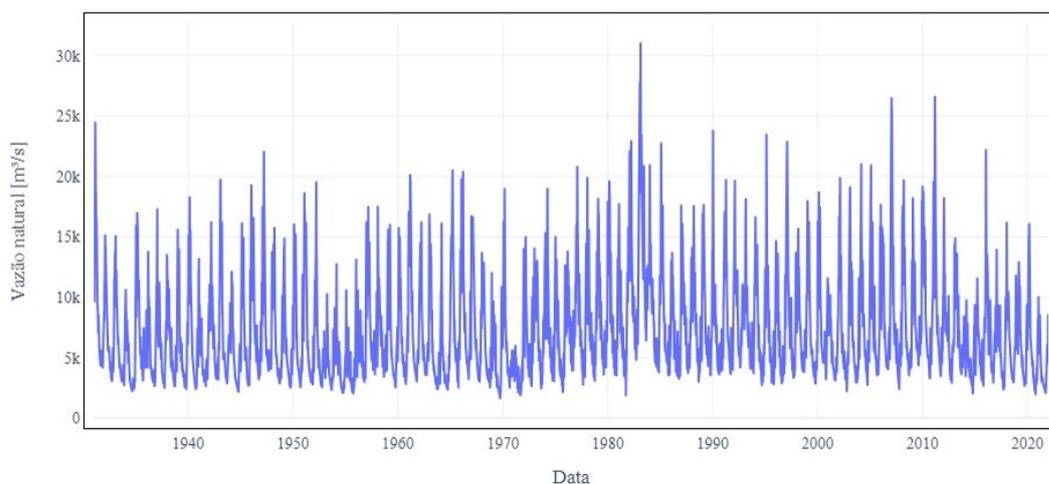
valores de vazão do local de estudo influenciam diretamente o comportamento hidrológico da região (MEURER; MARTINS; FILHO, 2005) e o planejamento de operação de curto prazo da Usina Hidrelétrica de Itaipu, onde a Divisão de Programação e Estatística (OPSP.DT) realiza a programação diária (PDO) e semanal de operação (PSO) para períodos futuros de um e nove dias, respectivamente. Para isso, inúmeras informações são levadas em consideração, mas uma das mais importantes é a vazão na afluência (BELOTTI, 2019). A base de dados contendo os valores médios diários de vazão natural do Aproveitamento Hidrelétrico de Porto Primavera e utilizada para avaliar o desempenho das redes neurais artificiais possui 33238 instâncias (Figura 10). Para o período de monitoramento considerado, o maior valor de vazão natural observado foi de 31088 m³/s em 16 de fevereiro de 1983 e o menor de 1579 m³/s ocorrido em 23 de setembro de 1969. Já o gráfico de barras da figura 11 exibe a média mensal dos valores médios diários de vazão natural, considerando todo o período de monitoramento. A partir dele, é possível observar que as maiores vazões ocorreram nos meses de janeiro, fevereiro, março, abril e dezembro e as menores nos meses de maio a novembro. O mês de fevereiro apresentou a maior média diária de vazão natural com 12095 m³/s e o mês de setembro a menor com 3780 m³/s.

Figura 9 – Rede de integração energética



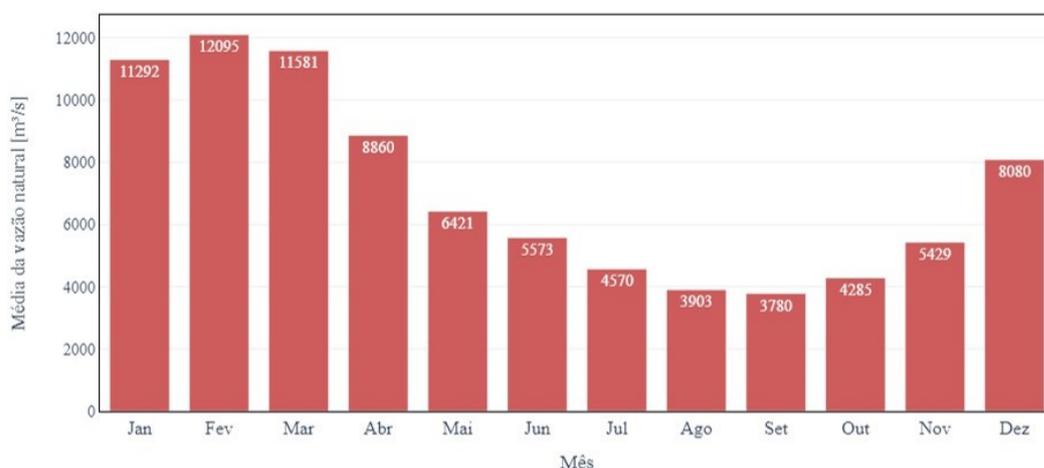
Fonte: <<https://www.itaipu.gov.br/>>

Figura 10 – Média diária da vazão natural do posto hidrelétrico de Porto Primavera



Fonte: Elaborada pelo autor

Figura 11 – Média mensal da vazão natural do posto hidrelétrico de Porto Primavera



Fonte: Elaborada pelo autor

3.2 Pré-processamento

A base de dados foi dividida de forma que 85% das instâncias foram utilizadas para o treinamento dos modelos, 10% para validação e 5% para teste. O conjunto de dados foi normalizado entre -1 e 1, utilizando a classe *MinMaxScaler* da biblioteca *scikit-learn*. Os dados de treinamento, validação e teste foram subdivididos em entradas e rótulos. As entradas representam a janela de tempo utilizada para prever os valores futuros. O exemplo da figura 12 considera sete valores de entrada e um rótulo. A cada iteração, tanto as entradas quanto o rótulo deslizam uma posição.

3.3 Hiperparâmetros e Janela de Tempo

O desempenho das previsões realizadas pelas redes neurais artificiais depende da seleção de seus hiperparâmetros e da escolha do número de entradas ou janela de tempo

em relação ao(s) rótulo(s). Para isso, alguns estudos recentes consideram a utilização de métodos estatísticos, algoritmos evolutivos e baseados em experimentos (SURAKHI et al., 2021). Neste caso, o número de entradas considerado para o modelo final foi obtido a partir da análise dos valores médios das métricas de desempenho no conjunto dos dados de teste após dez execuções dos algoritmos, levando em consideração uma janela de tempo de um a dez dias de antecedência para a Previsão Diária de Operação (PDO) e de nove a 18 dias de antecedência para a Previsão Semanal de Operação (PSO), conforme ilustra a figura 13. Estabelecida janela de tempo, os modelos de aprendizagem de máquina deverão prever os valores médios diários de vazão natural para um e nove dias. Serão avaliadas as métricas de desempenho das Redes Neurais Artificiais Perceptron Multicamadas (RNA-MLP), Redes Neurais Recorrentes simples (RNR), Memória Longa de Curto Prazo (LSTM) e *Gated Recurrent Unit* (GRU), além do tempo de execução. A tabela 1 relaciona os hiperparâmetros adotados através da tentativa e erro para as redes neurais artificiais consideradas nesta etapa.

Figura 12 – Entradas e rótulos com janela deslizante



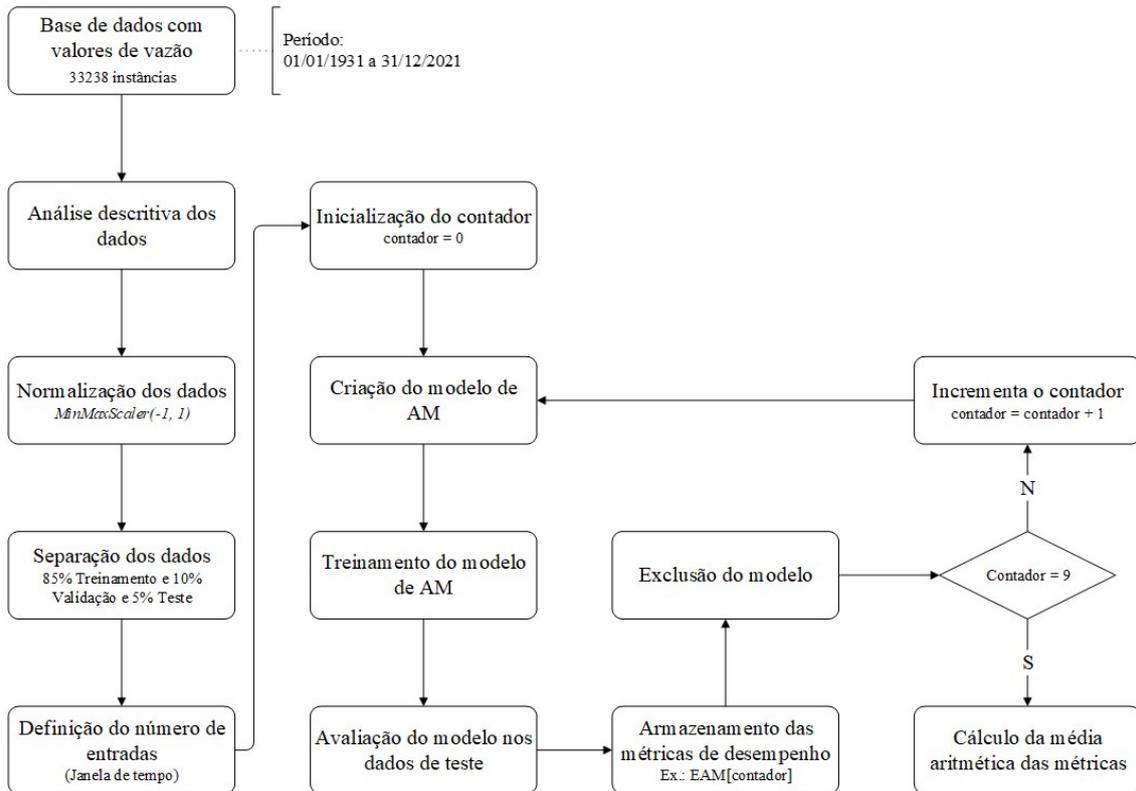
Fonte: Elaborada pelo autor

Tabela 1 – Hiperparâmetros das redes neurais artificiais

Hiperparâmetro	Valor
Neurônios	20
Épocas	20
Camadas ocultas	2
Taxa de aprendizagem	0.01
Função de ativação	tanh

Fonte: Elaborada pelo autor

Figura 13 – Sequência das etapas para a escolha da janela de tempo



Fonte: Elaborada pelo autor

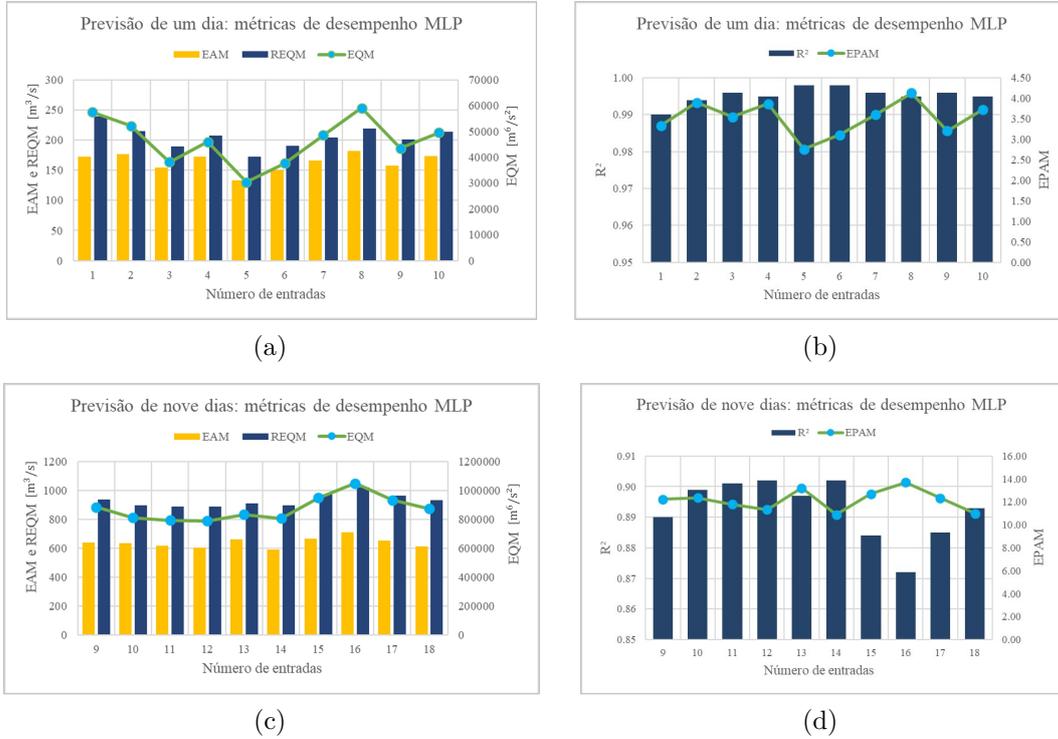
4 Análise dos Resultados

4.1 RNA Perceptron Multicamadas

Para a rede neural artificial Perceptron Multicamadas (RNA-MLP), são necessários cinco dias consecutivos (entradas) para prever o valor de vazão natural para o próximo dia. Os gráficos das figuras 14a e 14b e a tabela 2 apontam que os valores médios das métricas de desempenho após dez execuções do algoritmo para esta janela de tempo foram de 133,20 m³/s para o Erro Absoluto Médio (EAM), 2,76% para o Erro Percentual Absoluto Médio, 30346,62 m⁶/s² para o Erro Quadrático Médio (EQM), 172,37 m³/s para a Raiz do Erro Quadrático Médio (REQM) e um para o coeficiente de determinação (R²). Para estimar o valor de vazão natural para nove dias consecutivos, a janela de tempo considerada foi de 14 dias. Os gráficos das figuras 14c e 14d e a tabela 3 indicam que, apesar de apresentar um Erro Quadrático Médio (EQM) de 808121,07 m⁶/s² e Raiz do Erro Quadrático Médio (REQM) de 898,30 m³/s, maiores que os valores registrados para onze e doze entradas, o Erro Absoluto Médio (EAM) de 590,29 m³/s e o Erro Percentual Absoluto Médio (EPAM) de 10,90% foram menores em comparação com os outros intervalos. Além disso, o Erro Quadrático Médio (EQM) tem como objetivo identificar a ocorrência de erros bastante discrepantes, pois eleva seus valores ao quadrado. Para a janela de tempo considerada de 14 dias, o valor do coeficiente de determinação (R²) foi de 0,90. Os gráficos das figuras 15 e 17 sobrepõem os valores médios de vazão natural observados e previstos para o conjunto dos dados de teste, considerando os horizontes de previsão de um e nove dias. Os gráficos de dispersão das figuras 16 e 18 relacionam os valores observados ou reais (eixo x) e os valores

previstos (eixo y). A inclinação da linha de tendência está relacionada com o coeficiente de determinação (R^2).

Figura 14 – Métricas de desempenho em função do número de entradas (RNA-MLP)



Fonte: Elaborada pelo autor

Tabela 2 – Métricas de desempenho RNA-MLP: previsão de 1 dia

Entradas	Dias	R^2	EAM [m³/s]	EPAM [%]	EQM [m⁶/s²]	REQM [m³/s]
1	1	0,99	172,06	3,33	57474,76	239,50
2	1	0,99	176,38	3,90	52160,82	215,15
3	1	1,00	154,47	3,54	38127,35	188,81
4	1	1,00	172,76	3,86	45958,10	207,53
5	1	1,00	133,20	2,76	30346,62	172,37
6	1	1,00	150,56	3,11	37654,83	190,36
7	1	1,00	165,71	3,60	48512,54	203,68
8	1	1,00	181,82	4,13	59042,50	218,54
9	1	1,00	157,20	3,21	43460,34	200,86
10	1	1,00	173,59	3,73	49553,90	213,24
Média		1,00	163,77	3,52	46229,17	205,00

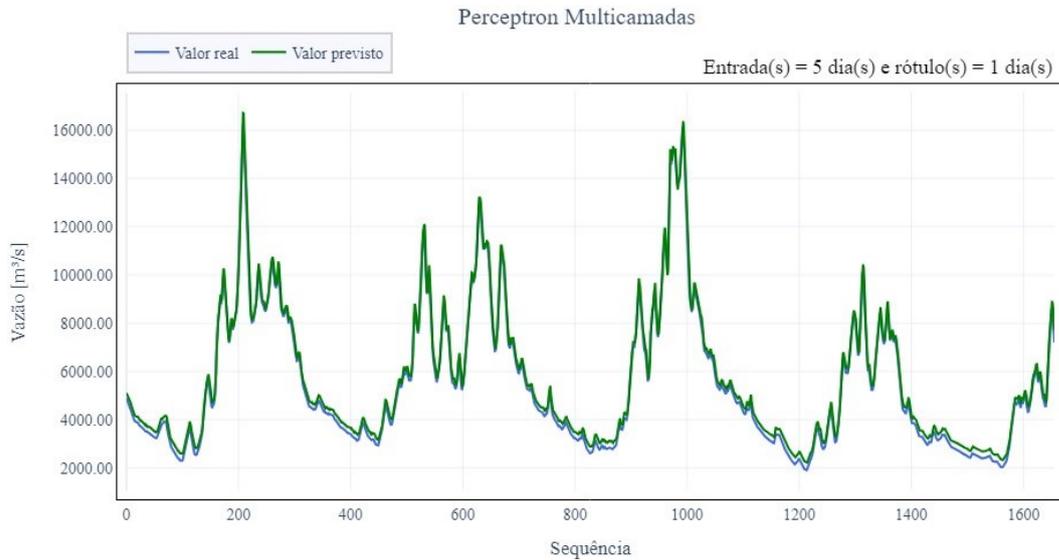
Fonte: Elaborada pelo autor

Tabela 3 – Métricas de desempenho RNA-MLP: previsão de 9 dias

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
9	9	0,89	642,61	12,23	886334,35	938,38
10	9	0,90	637,82	12,37	813967,38	901,12
11	9	0,90	618,18	11,81	795365,64	889,04
12	9	0,90	606,73	11,33	790918,31	887,81
13	9	0,90	661,80	13,21	836145,07	910,42
14	9	0,90	590,29	10,90	808121,07	898,30
15	9	0,88	667,99	12,70	951038,11	974,17
16	9	0,87	712,76	13,71	1050441,98	1021,68
17	9	0,89	654,11	12,33	935901,43	966,68
18	9	0,89	615,01	11,00	875441,41	935,04
Média		0,89	640,73	12,16	874367,48	932,26

Fonte: Elaborada pelo autor

Figura 15 – Valores reais e previstos RNA-MLP para 1 dia de previsão

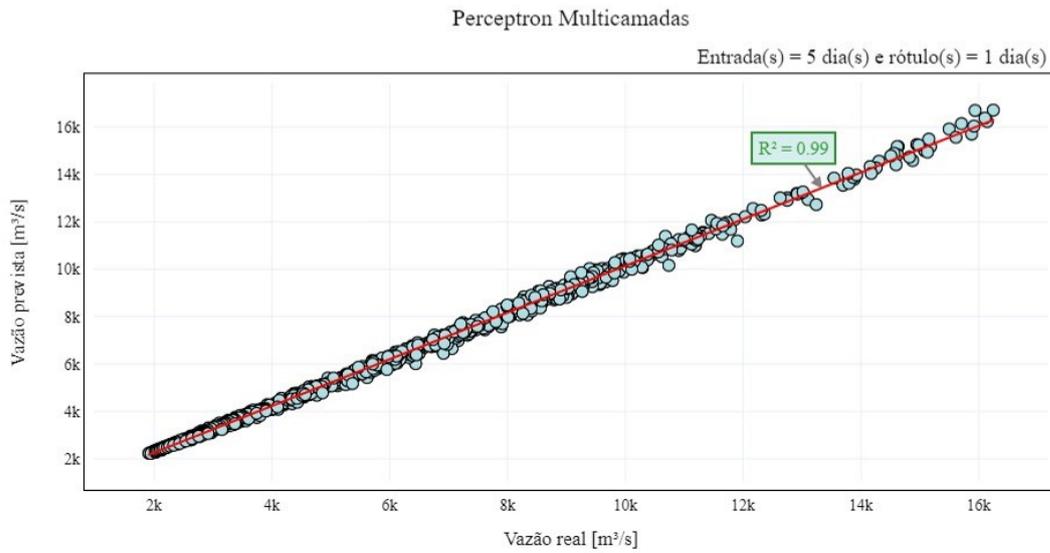


Fonte: Elaborada pelo autor

4.2 Redes Neurais Recorrentes

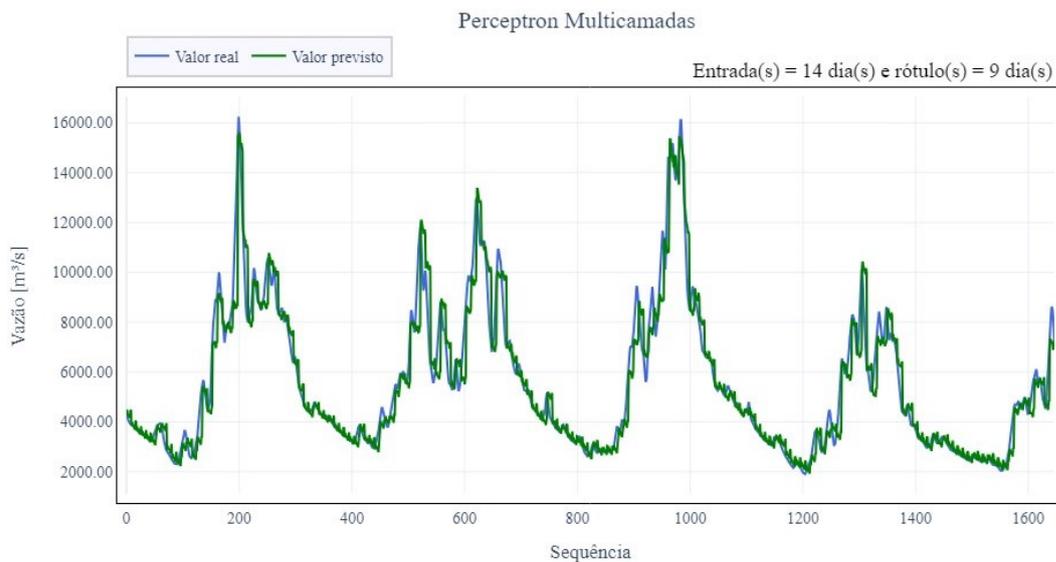
Para a rede neural recorrente (RNR) simples, são necessários dez dias consecutivos (entradas) para prever o valor de vazão natural para o próximo dia. Os gráficos das figuras 19a e 19b e a tabela 4 apontam que os valores médios das métricas de desempenho após dez execuções do algoritmo para esta janela de tempo foram de 124,54 m³/s para o Erro Absoluto Médio (EAM), 2,38% para o Erro Percentual Absoluto Médio, 28376,83 m⁶/s² para o Erro Quadrático Médio (EQM), 166,42 m³/s para a Raiz do Erro Quadrático Médio (REQM) e um para o coeficiente de determinação (R²). Para estimar o valor de vazão natural para nove dias consecutivos, a janela de tempo considerada foi de treze dias. Os gráficos das figuras 19c e 19d e a tabela 5 indicam um Erro Absoluto Médio (EAM) de 546,91 m³/s, um Erro Percentual Absoluto Médio (EPAM) de 10,01%, um Erro Quadrático Médio (EQM) de 689548,99 m⁶/s², Raiz do Erro Quadrático Médio (REQM) de 829,99

Figura 16 – Coeficiente de determinação RNA-MLP para 1 dia de previsão



Fonte: Elaborada pelo autor

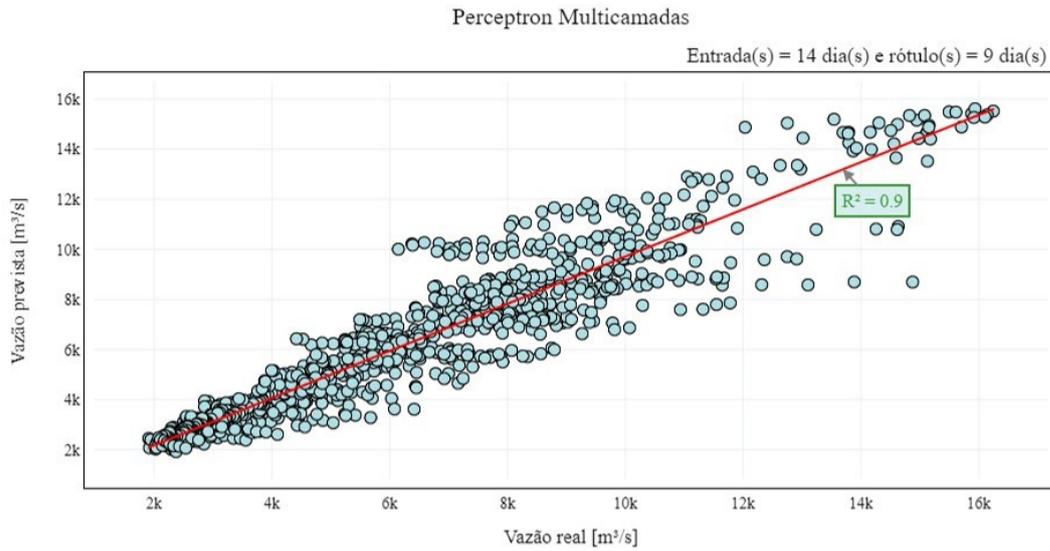
Figura 17 – Valores reais e previstos RNA-MLP para 9 dias de previsão



Fonte: Elaborada pelo autor

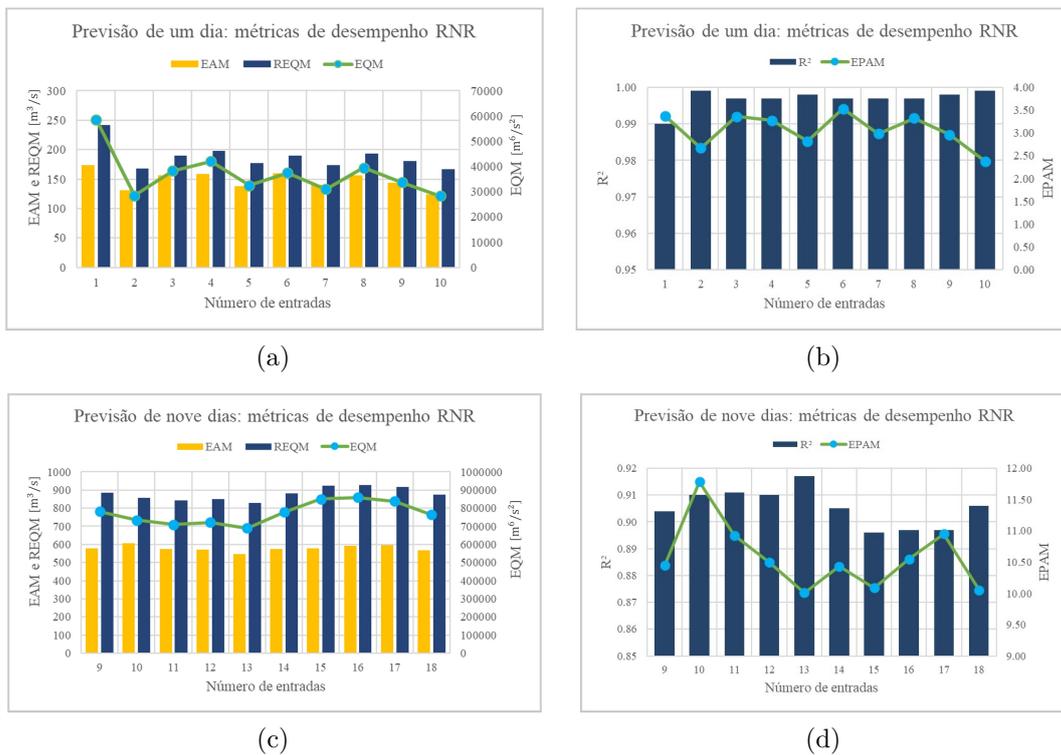
m^3/s e coeficiente de determinação (R^2) de 0,92. Os gráficos das figuras 20 e 22 sobrepõem os valores médios de vazão natural observados e previstos para a base de dados de teste, considerando um horizonte de previsão de um e nove dias. Os gráficos de dispersão das figuras 21 e 23 relacionam os valores observados ou reais (eixo x) e os valores previstos (eixo y). A inclinação da linha de tendência está relacionada com o coeficiente de determinação (R^2).

Figura 18 – Coeficiente de determinação RNA-MLP para 9 dias de previsão



Fonte: Elaborada pelo autor

Figura 19 – Métricas de desempenho em função do número de entradas (RNR)



Fonte: Elaborada pelo autor

Tabela 4 – Métricas de desempenho RNR: previsão de 1 dia

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
1	1	0,99	173,49	3,38	58664,49	241,65
2	1	1,00	130,46	2,67	28446,52	167,52
3	1	1,00	155,96	3,36	38256,87	190,10
4	1	1,00	158,36	3,28	42079,99	198,44
5	1	1,00	137,54	2,82	32535,04	177,40
6	1	1,00	159,47	3,53	37439,44	189,45
7	1	1,00	140,48	2,99	30981,22	173,49
8	1	1,00	156,69	3,33	39453,74	192,94
9	1	1,00	144,19	2,96	33731,08	180,24
10	1	1,00	124,54	2,38	28376,83	166,42
Média		1,00	148,12	3,07	36996,52	187,76

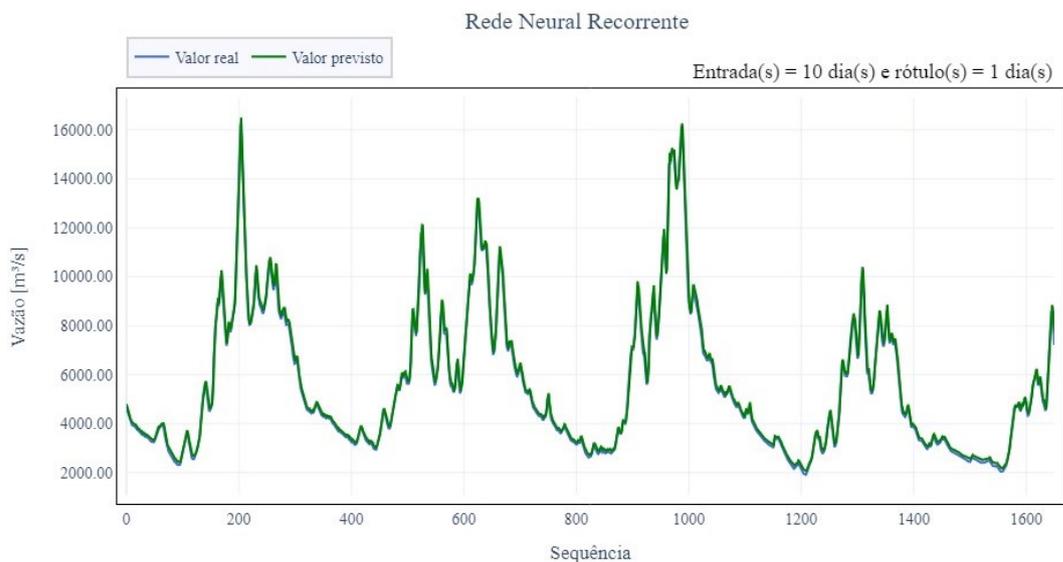
Fonte: Elaborada pelo autor

Tabela 5 – Métricas de desempenho RNR: previsão de 9 dias

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
9	9	0,90	578,54	10,45	782344,18	884,26
10	9	0,91	604,99	11,79	734671,64	856,57
11	9	0,91	575,86	10,93	710379,88	842,32
12	9	0,91	571,12	10,50	721971,47	849,48
13	9	0,92	546,91	10,01	689548,99	829,99
14	9	0,91	575,80	10,43	778796,52	882,06
15	9	0,90	578,86	10,09	851174,44	922,40
16	9	0,90	591,96	10,55	859819,75	927,15
17	9	0,90	597,47	10,95	837758,99	915,10
18	9	0,91	567,07	10,05	763402,70	873,47
Média		0,91	578,86	10,57	772986,86	878,28

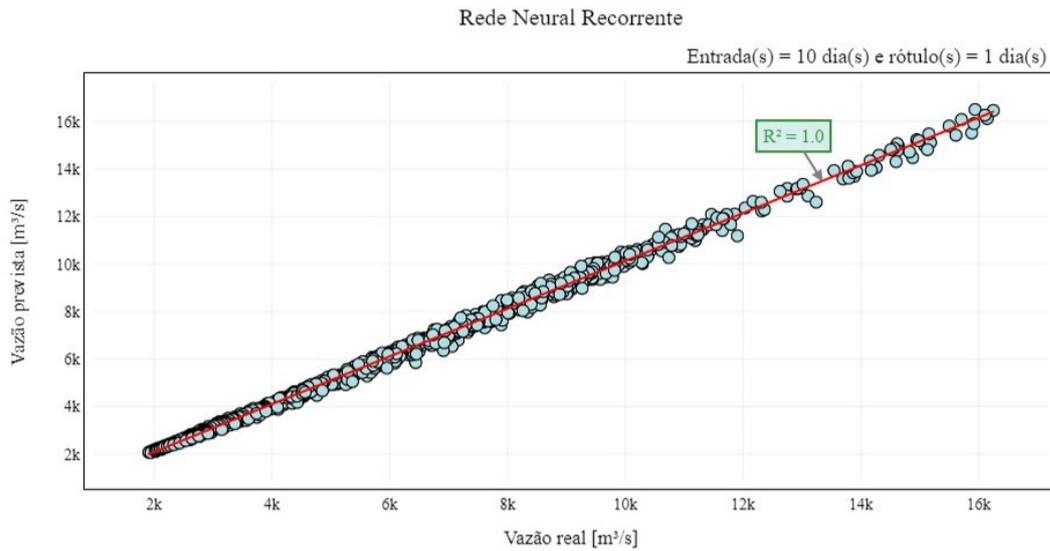
Fonte: Elaborada pelo autor

Figura 20 – Valores reais e previstos RNR simples para 1 dia de previsão



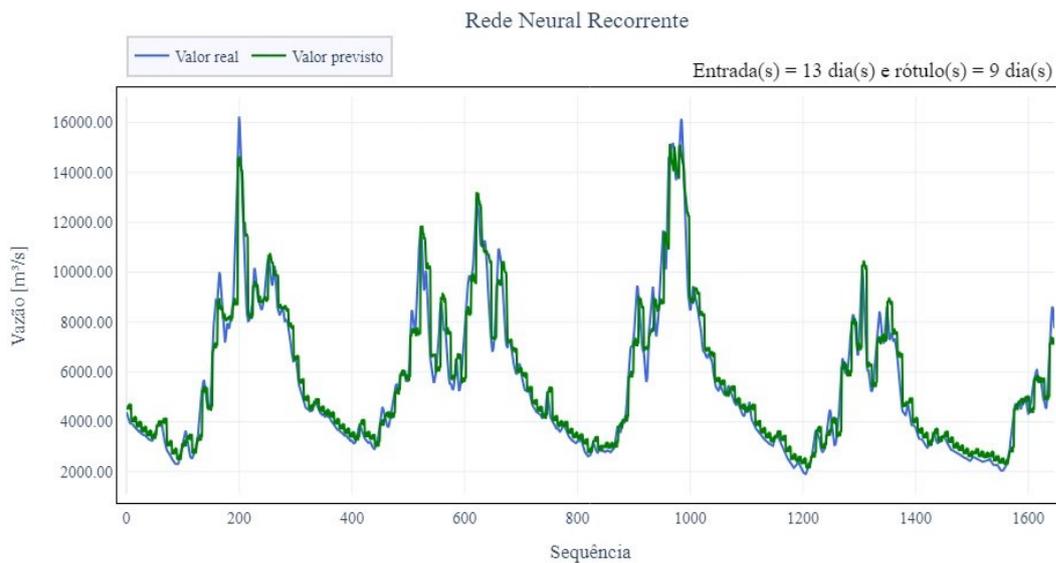
Fonte: Elaborada pelo autor

Figura 21 – Coeficiente de determinação RNR simples para 1 dia de previsão



Fonte: Elaborada pelo autor

Figura 22 – Valores reais e previstos RNR simples para 9 dias de previsão

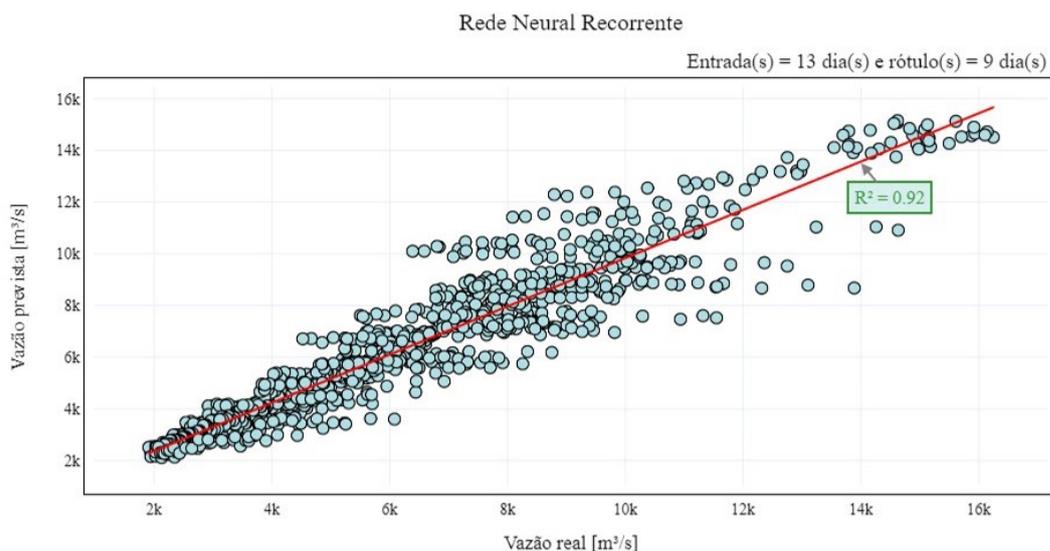


Fonte: Elaborada pelo autor

4.3 Memória Longa de Curto Prazo (LSTM)

Já para a rede neural recorrente do tipo memória longa de curto prazo (LSTM), são necessários quatro dias consecutivos (entradas) para prever o valor de vazão natural para o próximo dia. Os gráficos das figuras 24a e 24b e a tabela 6 indicam que, apesar de apresentar um Erro Quadrático Médio (EQM) de 20934,95 m^6/s^2 e Raiz do Erro Quadrático Médio (REQM) de 144,10 m^3/s pouco maiores que os valores registrados para oito entradas, o Erro Absoluto Médio (EAM) de 105,20 m^3/s e o Erro Percentual Absoluto Médio (EPAM) de 2,02% foram menores em comparação com os outros intervalos. Da mesma forma que

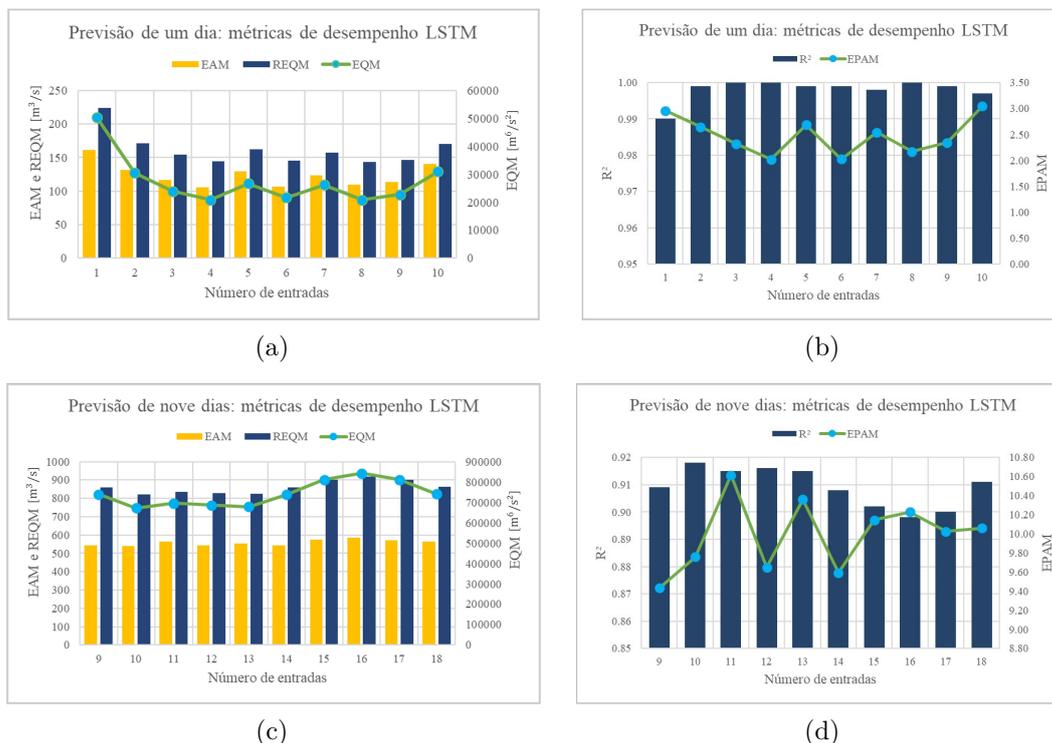
Figura 23 – Coeficiente de determinação RNR simples para 9 dias de previsão



Fonte: Elaborada pelo autor

no caso das redes neurais artificiais do tipo perceptron multicamadas, o Erro Quadrático Médio (EQM) tem como objetivo identificar a ocorrência de erros bastante discrepantes. Para esta janela de tempo, o valor do coeficiente de determinação (R^2) foi igual a um. Para estimar o valor de vazão natural para nove dias consecutivos, a janela de tempo considerada foi de dez dias. Os gráficos das figuras 24c e 24d e a tabela 7 indicam que, apesar de apresentar um Erro Percentual Absoluto Médio (EPAM) de 9,76%, maior que os valores registrados para nove, doze e 14 entradas, o Erro Absoluto Médio (EAM) de 538,94 m^3/s , o Erro Quadrático Médio (EQM) de 672153,67 m^6/s^2 e a Raiz do Erro Quadrático Médio (REQM) de 819,69 m^3/s foram menores em comparação com os outros intervalos. Vale ressaltar que as métricas de desempenho devem ser avaliadas em conjunto, ou seja, somente um valor menor para o Erro Percentual Absoluto Médio (EPAM) não é suficiente para tecer conclusões a respeito do desempenho de um modelo. Para a janela de tempo considerada de dez dias, o valor do coeficiente de determinação (R^2) foi de 0,92. Os gráficos das figuras 25 e 27 sobrepõem os valores médios de vazão natural observados e previstos para a base de dados de testes, considerando um horizonte de previsão de um e nove dias. Os gráficos de dispersão (Figuras 26 e 28) relacionam os valores observados ou reais (eixo x) e os valores previstos (eixo y). A inclinação da linha de tendência está relacionada com o coeficiente de determinação (R^2).

Figura 24 – Métricas de desempenho em função do número de entradas (LSTM)



Fonte: Elaborada pelo autor

Tabela 6 – Métricas de desempenho LSTM: previsão de 1 dia

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
1	1	0,99	161,11	2,96	50535,12	224,54
2	1	1,00	131,82	2,65	30574,27	171,56
3	1	1,00	117,07	2,32	24015,60	154,41
4	1	1,00	105,20	2,02	20934,95	144,10
5	1	1,00	129,35	2,69	26750,37	161,89
6	1	1,00	106,81	2,03	21724,01	145,68
7	1	1,00	123,85	2,54	26291,30	157,16
8	1	1,00	109,33	2,17	20883,04	143,07
9	1	1,00	113,15	2,34	22783,74	146,76
10	1	1,00	140,70	3,05	31037,09	170,71
Média		1,00	123,84	2,48	27552,95	161,99

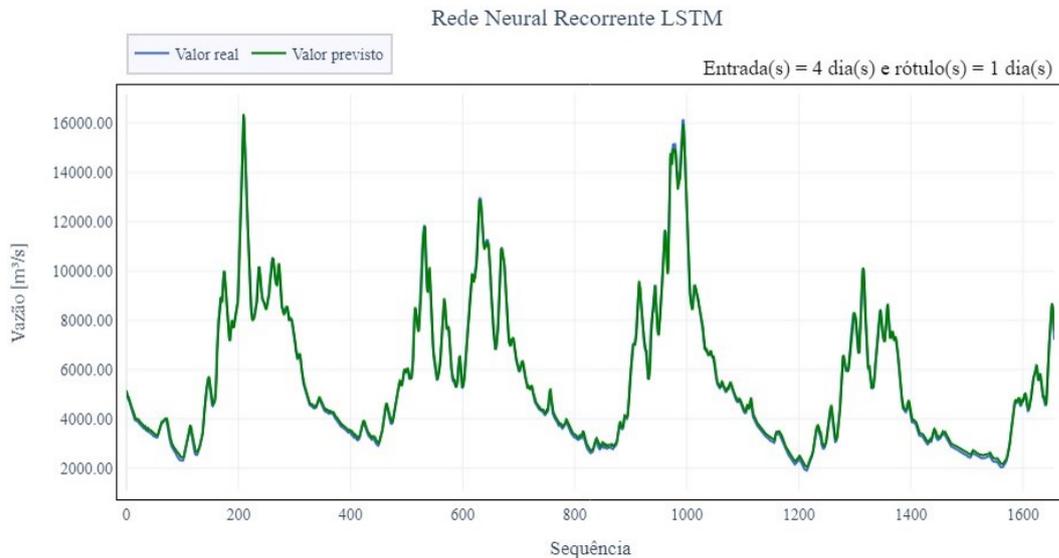
Fonte: Elaborada pelo autor

Tabela 7 – Métricas de desempenho LSTM: previsão de 9 dias

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
9	9	0,91	543,74	9,43	739392,78	859,67
10	9	0,92	538,94	9,76	672153,67	819,69
11	9	0,92	564,96	10,62	696291,46	834,00
12	9	0,92	542,12	9,65	687284,00	828,85
13	9	0,92	554,67	10,36	679663,65	823,79
14	9	0,91	544,26	9,59	738733,94	859,27
15	9	0,90	573,87	10,15	812027,76	900,90
16	9	0,90	583,24	10,23	843060,72	917,94
17	9	0,90	571,09	10,03	811895,83	900,98
18	9	0,91	564,52	10,06	742229,34	861,44
Média		0,91	558,14	9,99	742273,31	860,65

Fonte: Elaborada pelo autor

Figura 25 – Valores reais e previstos RNR-LSTM para 1 dia de previsão

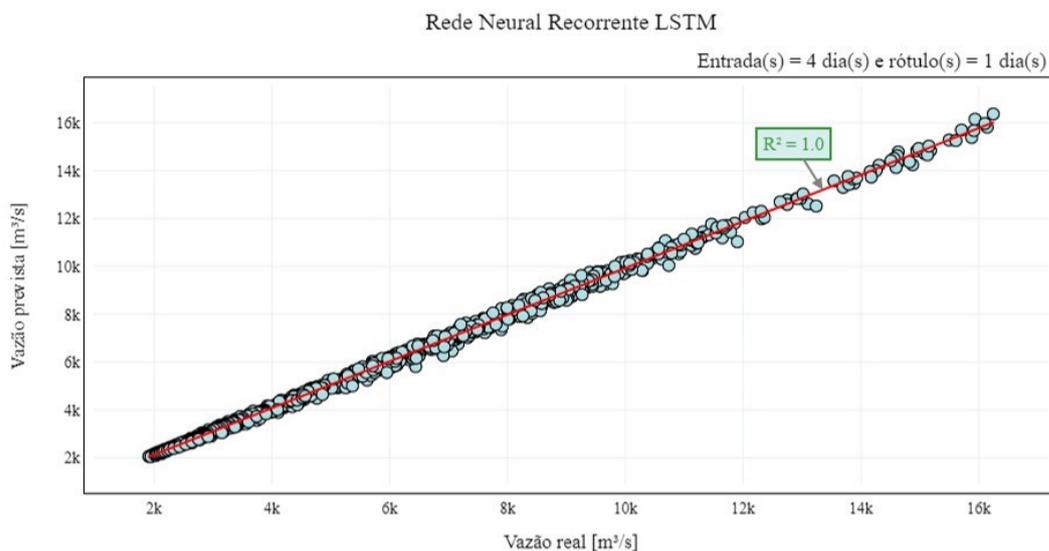


Fonte: Elaborada pelo autor

4.4 Gated Recurrent Unit (GRU)

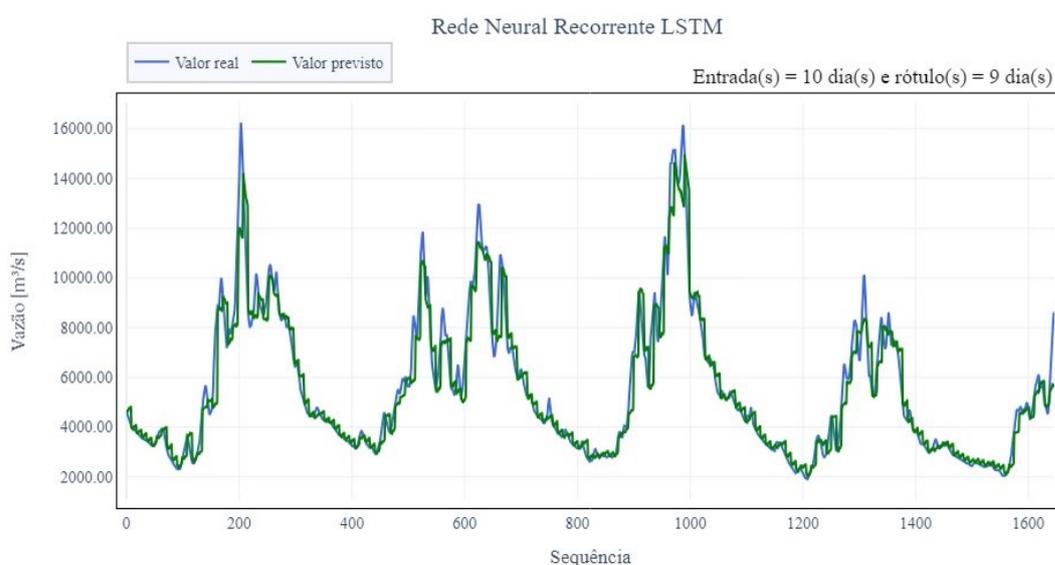
Finalmente, para a rede neural artificial do tipo *Gated Recurrent Unit* (GRU), são necessários dois dias consecutivos (entradas) para prever o valor de vazão natural para o próximo dia. Os gráficos das figuras 29a e 29b e a tabela 8 apontam que os valores médios das métricas de desempenho após dez execuções do algoritmo para esta janela de tempo foram de 112,18 m³/s para o Erro Absoluto Médio (EAM), 2,17% para o Erro Percentual Absoluto Médio, 23042,65 m⁶/s² para o Erro Quadrático Médio (EQM), 151,23 m³/s para a Raiz do Erro Quadrático Médio (REQM) e um para o coeficiente de determinação (R²). Para estimar o valor de vazão natural para nove dias consecutivos, a janela de tempo considerada foi de onze dias. Os gráficos das figuras 29c e 29d e a tabela 9 indicam que, apesar de apresentar um Erro Percentual Absoluto Médio (EPAM) de 9,26%, pouco maior que o valor registrado para doze entradas, o Erro Absoluto Médio (EAM) de 527,00 m³/s,

Figura 26 – Coeficiente de determinação RNR-LSTM para 1 dia de previsão



Fonte: Elaborada pelo autor

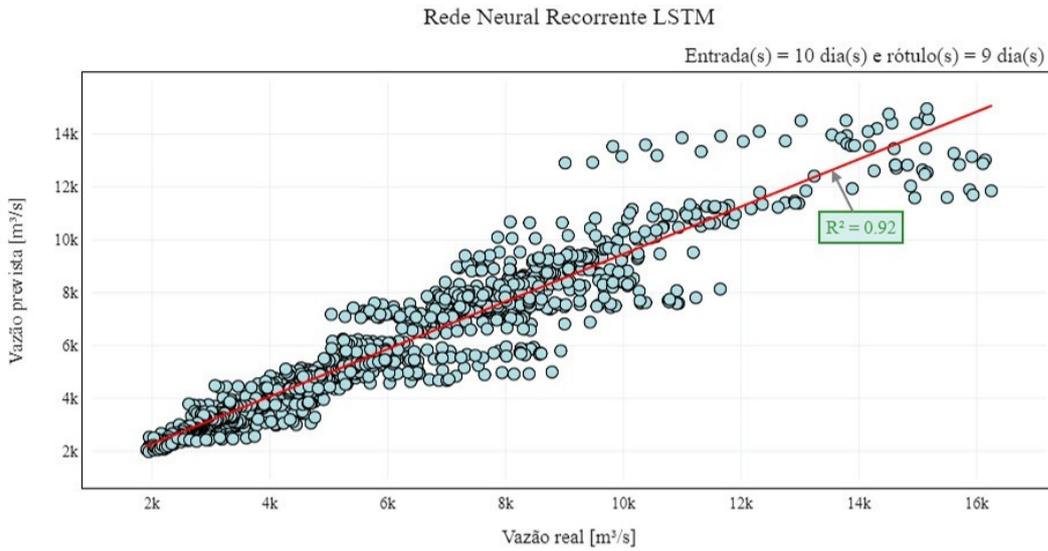
Figura 27 – Valores reais e previstos RNR-LSTM para 9 dias de previsão



Fonte: Elaborada pelo autor

o Erro Quadrático Médio (EQM) de $679608,29 \text{ m}^6/\text{s}^2$ e a Raiz do Erro Quadrático Médio (REQM) de $824,07 \text{ m}^3/\text{s}$ foram menores em comparação com os outros intervalos. Da mesma forma que no caso da rede neural recorrente do tipo memória longa de curto prazo, as métricas de desempenho devem ser avaliadas em conjunto, ou seja, somente um valor menor para o Erro Percentual Absoluto Médio (EPAM) não é suficiente para tecer conclusões a respeito do desempenho de um modelo. Para a janela de tempo considerada de onze dias, o valor do coeficiente de determinação (R^2) foi de 0,92. Os gráficos das figuras 30 e 32 sobrepõem os valores médios de vazão natural observados e previstos para a base de dados de teste, considerando um horizonte de previsão de um e nove dias. Os gráficos de

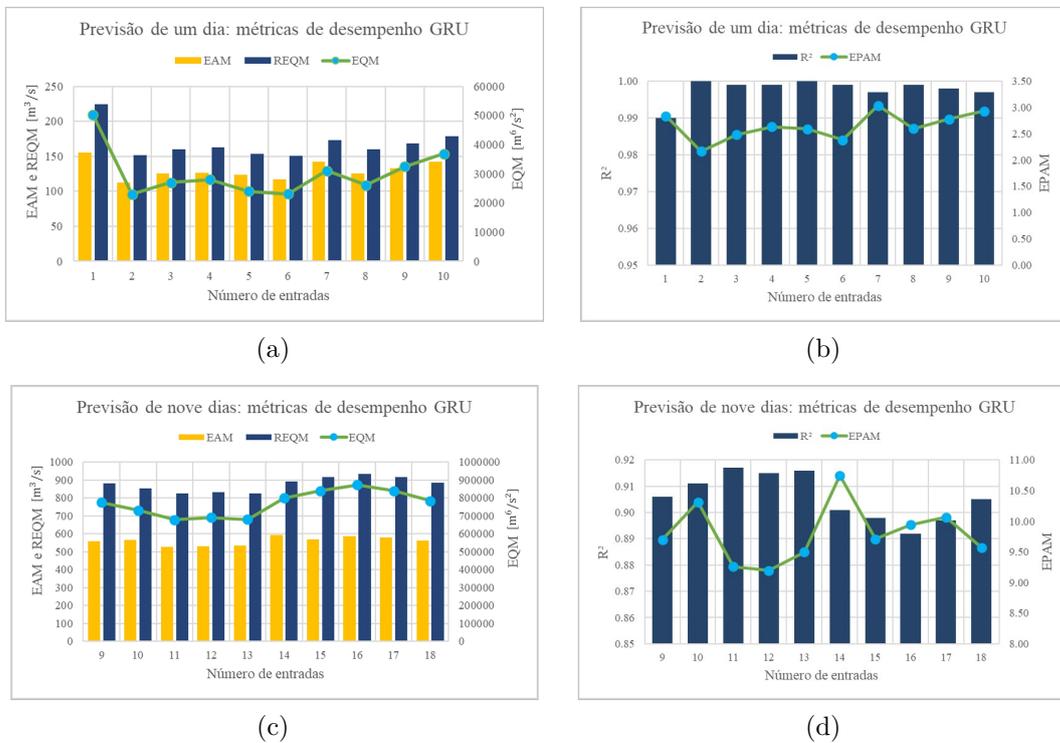
Figura 28 – Coeficiente de determinação RNR-LSTM para 9 dias de previsão



Fonte: Elaborada pelo autor

dispersão das figuras 31 e 33 relacionam os valores observados ou reais (eixo x) e os valores previstos (eixo y). A inclinação da linha de tendência está relacionada com o coeficiente de determinação (R^2).

Figura 29 – Métricas de desempenho em função do número de entradas (GRU)



Fonte: Elaborada pelo autor

Tabela 8 – Métricas de desempenho GRU: previsão de 1 dia

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
1	1	0,99	155,46	2,84	50194,74	223,98
2	1	1,00	112,18	2,17	23042,65	151,23
3	1	1,00	125,78	2,48	27000,51	160,34
4	1	1,00	126,63	2,64	28011,98	162,82
5	1	1,00	123,70	2,59	23957,76	153,50
6	1	1,00	117,33	2,38	23161,86	150,50
7	1	1,00	142,58	3,04	31032,16	172,89
8	1	1,00	125,42	2,60	26162,72	159,65
9	1	1,00	132,89	2,78	32549,71	168,45
10	1	1,00	142,13	2,93	36875,19	178,94
Média		1,00	130,41	2,64	30198,93	168,23

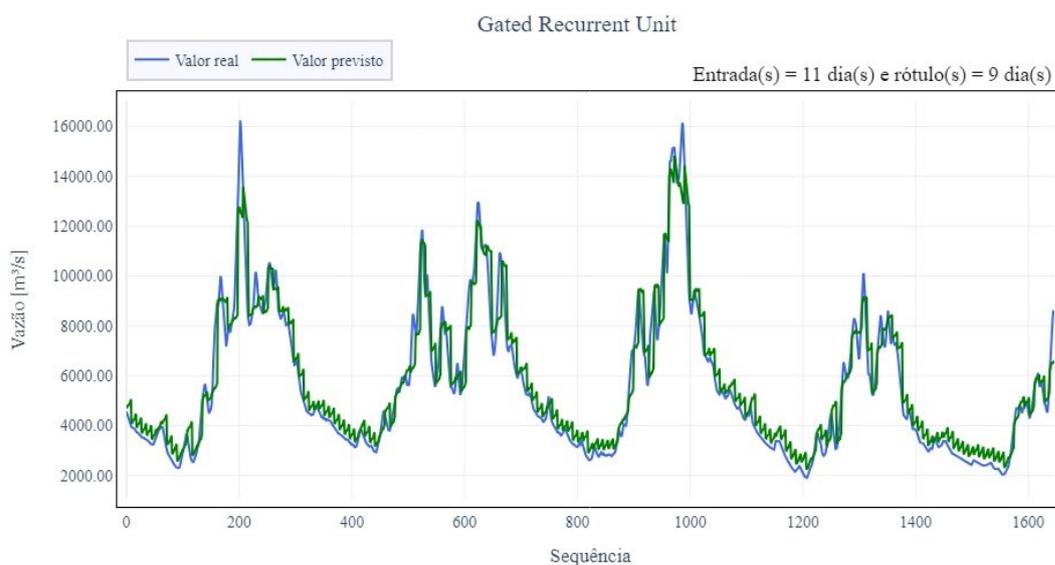
Fonte: Elaborada pelo autor

Tabela 9 – Métricas de desempenho GRU: previsão de 9 dias

Entradas	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]
9	9	0,91	557,04	9,70	775253,12	880,13
10	9	0,91	565,67	10,31	730903,27	853,18
11	9	0,92	527,00	9,26	679608,29	824,07
12	9	0,92	529,70	9,20	690641,23	830,96
13	9	0,92	534,12	9,50	680424,87	824,75
14	9	0,90	592,88	10,75	799161,98	893,11
15	9	0,90	569,62	9,71	840664,72	916,78
16	9	0,89	586,88	9,94	873748,11	934,53
17	9	0,90	580,93	10,07	841117,22	916,92
18	9	0,91	560,76	9,57	784744,33	885,69
Média		0,91	560,46	9,80	769626,71	876,01

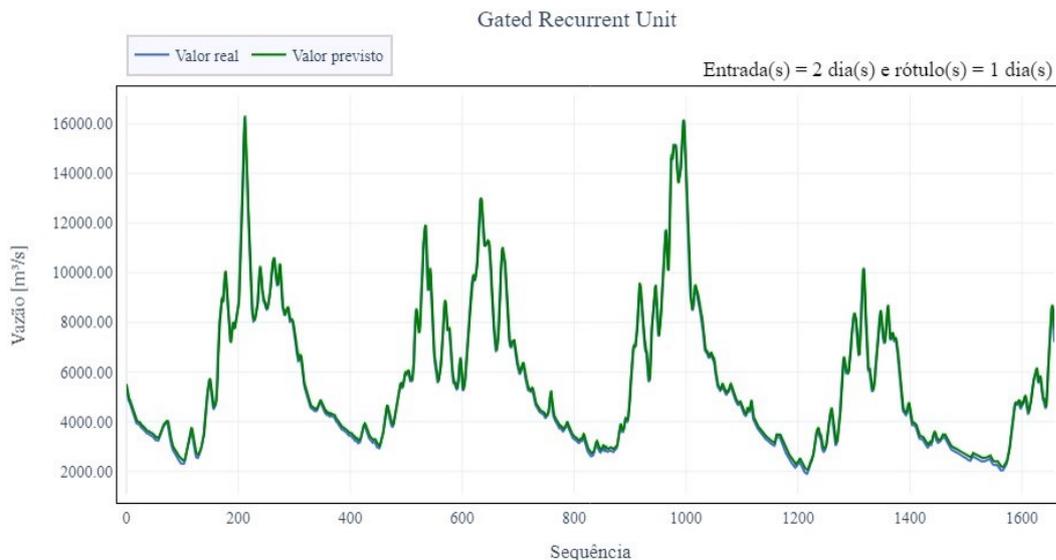
Fonte: Elaborada pelo autor

Figura 32 – Valores reais e previstos RNR-GRU para 9 dias de previsão



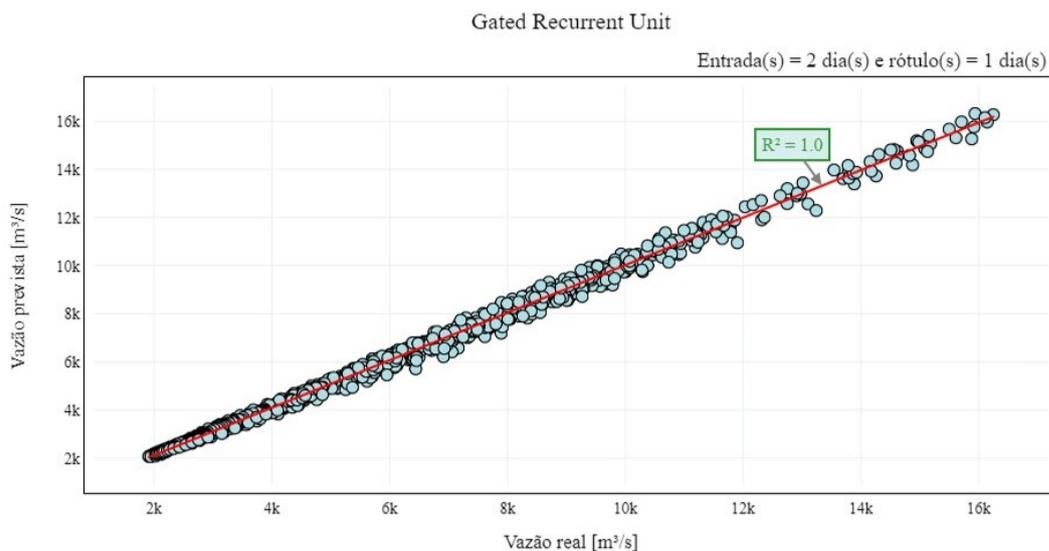
Fonte: Elaborada pelo autor

Figura 30 – Valores reais e previstos RNR-GRU para 1 dia de previsão



Fonte: Elaborada pelo autor

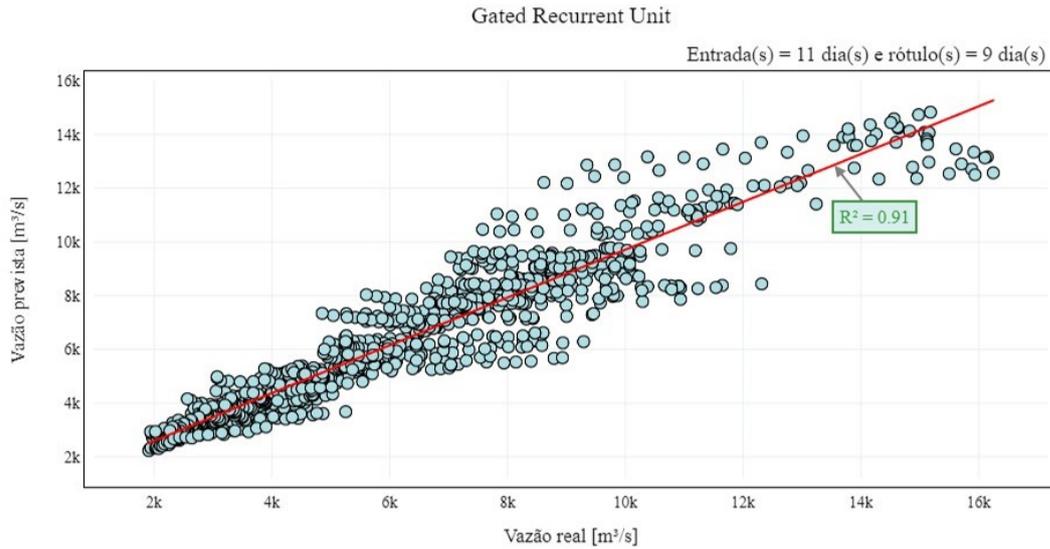
Figura 31 – Coeficiente de determinação RNR-GRU para 1 dia de previsão



Fonte: Elaborada pelo autor

A tabela 10 destaca as melhores métricas de desempenho de cada uma das redes neurais artificiais avaliadas. Para prever o valor de vazão natural do aproveitamento hidrelétrico de Porto Primavera para um intervalo de um dia, a rede neural artificial do tipo Memória Longa de Curto Prazo (LSTM) superou as outras arquiteturas, seguida dos modelos *Gated Recurrent Unit* (GRU), Rede Neural Recorrente (RNR) simples e rede neural artificial Perceptron Multicamadas (RNA-MLP). Por outro lado, foi a rede neural que levou mais tempo nos processos de compilação e treinamento (39,84 s). O tempo necessário para compilar e treinar o modelo de rede neural artificial Perceptron Multicamadas (RNA-MLP) foi, aproximadamente, oito vezes menor (4,99 s). No entanto,

Figura 33 – Coeficiente de determinação RNR-GRU para 9 dias de previsão



Fonte: Elaborada pelo autor

para este caso, esta arquitetura obteve as piores métricas de desempenho.

Já para prever os valores de vazão natural para nove dias consecutivos, a rede neural artificial do tipo *Gated Recurrent Unit* (GRU) obteve as melhores métricas de desempenho, seguida dos modelos Memória Longa de Curto Prazo (LSTM), Rede Neural Recorrente (RNR) simples e rede neural artificial Perceptron Multicamadas (RNA-MLP). Novamente, a rede neural artificial Perceptron Multicamadas (RNA-MLP) obteve o menor tempo para compilação e treinamento (6,27 s) e apresentou o pior desempenho.

Tabela 10 – Métricas de desempenho das redes neurais artificiais

Arquitetura	Dias	R ²	EAM [m ³ /s]	EPAM [%]	EQM [m ⁶ /s ²]	REQM [m ³ /s]	Tempo [s]
MLP	1	1,00	133,20	2,76	30346,62	172,37	4,99
RNR	1	1,00	124,54	2,38	28376,83	166,42	18,90
LSTM	1	1,00	105,20	2,02	20934,95	144,10	39,84
GRU	1	1,00	112,18	2,17	23042,65	151,23	22,26
MLP	9	0,90	590,29	10,90	808121,07	898,30	6,27
RNR	9	0,92	546,91	10,01	689548,99	829,99	30,91
LSTM	9	0,92	538,94	9,76	672153,67	819,69	56,46
GRU	9	0,92	527,00	9,26	679608,29	824,07	33,11

Fonte: Elaborada pelo autor

5 Conclusões

Os algoritmos de aprendizagem de máquina mostraram-se capazes de estimar os valores de vazão natural para um e nove dias do aproveitamento hidrelétrico de Porto Primavera. Comportamentos atípicos das variáveis climáticas sob os quais não se tem controle como, por exemplo, alterações nos índices pluviométricos que resultam em regimes de cheia ou estiagem severos podem comprometer as previsões realizadas, mas os resultados demonstraram que as redes neurais recorrentes são uma alternativa viável para auxiliar a

operação da Usina Hidrelétrica de Itaipu. As arquiteturas Memória Longa de Curto Prazo (LSTM) e *Gated Recurrent Unit* (GRU) apresentaram o melhor desempenho em prever os valores de vazão para um e nove dias, respectivamente. A previsão para um dia resultou em um Erro Absoluto Médio (EAM) de 105,20 m³/s e um Erro Percentual Absoluto Médio (EPAM) de 2,02%. Já a previsão para nove dias resultou em um Erro Absoluto Médio (EAM) de 527,00 m³/s e um Erro Percentual Absoluto Médio (EPAM) de 9,26%. A vazão natural do posto hidrelétrico de Porto Primavera é considerada um dos parâmetros mais importantes para a Usina Hidrelétrica de Itaipu, pois o nível na confluência dos rios Paraná e Iguazu não pode ultrapassar meio metro no intervalo de uma hora e dois metros de um dia para o outro, o que representa uma importante restrição operacional. Ademais, a diminuição do nível de água resultado da diminuição nos valores de vazão pode comprometer sua qualidade, pois intensifica a decomposição de matéria orgânica, aumenta a quantidade de sólidos totais e causa variações nos valores de temperatura e turbidez. Nesta situação, há também o risco de aprisionamento de peixes (AGOSTINHO; GOMES, 2021). Além de contribuir com o meio ambiente e com a otimização na geração de energia, a aprendizagem de máquina pode contribuir com outras áreas de conhecimento como a medicina diagnóstica, climatologia, administração de empresas e marketing estratégico.

Referências

- AGOSTINHO, A. A.; GOMES, L. C. *Relatório Técnico Final Redução da Vazão Deftuente UHE Eng. Sérgio Motta - Porto Primavera*. São Paulo, 2021. 225 p. Disponível em: <<https://www.gov.br/ana/pt-br>>. 28
- AGRAWAL, R. *Know The Best Evaluation Metrics for Your Regression Model*. 2021. Disponível em: <<https://www.analyticsvidhya.com/blog/2021/05/know-the-best-evaluation-metrics-for-your-regression-model/>>. 8
- ANA, A. N. d. A. e. S. B. *Evaporação líquida de reservatórios artificiais no Brasil*. Brasília: Agência Nacional de Águas e Saneamento Básico, 2021. ISBN 9786588101209. Disponível em: <https://biblioteca.ana.gov.br/sophia_web/acervo/detalhe/90848>. 2
- AURÉLIEN, G. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras & TensorFlow*. 2^a. ed. Starling Alta Editora e Consultoria Eireli, 2021. ISBN 978-85-508-1548-0. Disponível em: <<https://altabooks.com.br/>>. 4, 5
- BELOTTI, J. T. *Previsão de Vazões Afluentes Utilizando Redes Neurais Artificiais e Ensembles*. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2019. 10
- CASTRO, L. N. d.; FERRAI, D. G. *Introdução à Mineração de Dados: Conceitos Básicos, Algoritmos e Aplicações*. 1. ed. São Paulo: Saraiva, 2016. ISBN 978-85-472-0100-5. 4, 8
- CESP, C. E. d. S. P. *Porto Primavera*. 2023. Disponível em: <<https://www.cesp.com.br/>>. 8
- CNI, C. N. d. I. *Contribuições da CNI para a Agenda ESG na Indústria Brasileira*. Brasília: Confederação Nacional da Indústria, 2021. ISBN 978-65-86075-82-3. 3

- FAO, F. a. A. O. o. t. U. N. *The State of the World's Land and Water Resources for Food and Agriculture 2021 – Systems at breaking point*. FAO, 2022. ISBN 978-92-5-136127-6. Disponível em: <<https://www.fao.org/documents/card/en/c/cb9910en>>. 2
- GAMBA, C. T. de C. et al. *Plano de Ações para o Desenvolvimento Econômico Sustentável do Pontal do Paranapanema*. São Paulo: Secretaria de Desenvolvimento Econômico, 2022. 9
- HAO, Z. et al. A novel deep learning model for mining nonlinear dynamics in lake surface water temperature prediction. v. 15, n. 4, p. 900, 2023. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/15/4/900>>. 4
- HAYKIN, S. *Redes Neurais: Princípios e Prática*. Bookman Editora, 2001. ISBN 9788577800865. Disponível em: <<https://books.google.com.br/books?id=bhMwDwAAQBAJ>>. 4
- HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, nov. 1997. ISSN 0899-7667, 1530-888X. Disponível em: <<https://direct.mit.edu/neco/article/9/8/1735-1780/6109>>. 6
- JAN, F. et al. IoT-Based Solutions to Monitor Water Level, Leakage, and Motor Control for Smart Water Tanks. *Water*, v. 14, n. 3, p. 309, jan. 2022. ISSN 2073-4441. Disponível em: <<https://www.mdpi.com/2073-4441/14/3/309>>. 2, 3
- JENNY, H. et al. Using Artificial Intelligence for Smart Water Management Systems. In: . Asian Development Bank, 2020. (ADB Briefs), p. 10. ISBN 978-92-9262-269-5. Disponível em: <<https://www.adb.org/publications/artificial-intelligence-water-supply-ufw>>. 4
- MARENGO, J. et al. A seca e a crise hídrica de 2014-2015 em São Paulo. *Revista USP*, v. 106, p. 31, set. 2015. 1
- MEURER, M.; MARTINS, D. P.; FILHO, E. Elias de S. Dinâmica das vazões reguladas pelas usinas de Porto Primavera e Rosana, na região do Pontal do Paranapanema, no período 1999-2003. v. 20, p. 20, 2005. ISSN 2177-5230. Disponível em: <<https://periodicos.ufsc.br/index.php/geosul/article/view/13242>>. 10
- ONU, O. d. N. U. *46% da população global vive sem acesso a saneamento básico*. 2023. Disponível em: <<https://news.un.org/pt/story/2023/03/1811712>>. 2
- PLEVRIS, V. et al. Investigation of performance metrics in regression analysis and machine learning-based prediction models. In: . [S.l.: s.n.], 2022. 7
- READ, J. S. et al. Process-Guided Deep Learning Predictions of Lake Water Temperature. *Water Resources Research*, v. 55, n. 11, p. 9173–9190, 2019. _eprint: <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1029/2019WR024922>. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2019WR024922>>. 3
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, n. 6, p. 386–408, 1958. ISSN 1939-1471, 0033-295X. Disponível em: <<https://doi.apa.org/getdoi.cfm?doi=10.1037/h0042519>>. 4
- SURAKHI, O. et al. Time-Lag Selection for Time-Series Forecasting Using Neural Network and Heuristic Algorithm. *Electronics*, v. 10, n. 20, p. 2518, out. 2021. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/10/20/2518>>. 12

TRAN, T. T. K. et al. A Review of Neural Networks for Air Temperature Forecasting. *Water*, v. 13, n. 9, p. 1294, maio 2021. ISSN 2073-4441. Disponível em: <<https://www.mdpi.com/2073-4441/13/9/1294>>. 6