



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Previsão Sazonal de Vazões para a Usina Hidrelétrica de Boa Esperança-PI utilizando Redes Neurais Artificiais

¹David Lopes de Sousa, ²Francisco de Assis de Souza Filho, ³Rafael Brito Aguiar de Araujo, ⁴Guilherme Marques Farias, ⁵Marco Aurélio Holanda de Castro

¹Engenheiro Civil, Doutorando em Engenharia Civil (Recursos Hídricos) pela Universidade Federal do Ceará (UFC). E-mail: david.lopes2@hotmail.com. ORCID: <https://orcid.org/0000-0001-8041-9511>(autor correspondente). ²Engenheiro Civil, Doutor em Engenharia Civil pela Escola Politécnica da Universidade de São Paulo, Professor do Departamento de Engenharia Hidráulica e Ambiental da Universidade Federal do Ceará (UFC). E-mail: assis@ufc.br. ORCID: <https://orcid.org/0000-0001-5989-1731>. ³Engenheiro Civil, Doutorando em Engenharia Civil (Recursos Hídricos) pela Universidade Federal do Ceará (UFC). E-mail: rafaelbritodm@hotmail.com. ORCID: <https://orcid.org/0000-0002-6193-7564>. ⁴Engenheiro Civil, Doutorando em Engenharia Civil (Recursos Hídricos) pela Universidade Federal do Ceará (UFC). E-mail: guilhermemf15@gmail.com. ORCID: <https://orcid.org/0000-0002-6726-9210>. ⁵Engenheiro Civil, Ph.D. em Engenharia pela Drexel University. Professor do Departamento de Engenharia Hidráulica e Ambiental da Universidade Federal do Ceará (UFC). E-mail: marco@ufc.br. ORCID: <https://orcid.org/0000-0001-5134-7213>.

Artigo recebido em 23/02/2021 e aceito em 04/05/2021

RESUMO

Estudos que apresentam previsões climatológicas têm crescido em importância, na medida em que o aumento da demanda de água e energia cria uma necessidade de se obter informações sobre o comportamento futuro das fontes naturais. Este artigo apresenta dois modelos de previsão de vazões médias do Rio Parnaíba, na altura da Usina Hidrelétrica de Boa Esperança, para os períodos de outubro a dezembro e de janeiro a abril, épocas que apresentam os maiores valores médios para essa variável hidrológica no local. Como preditores, foram utilizados índices climáticos relacionados a temperatura da superfície do mar, os quais foram escolhidos através da análise de teleconexões já conhecidas da literatura e das correlações calculadas entre as vazões observadas e os valores médios dos índices com diferentes defasagens. Em seguida, foram construídas Redes Neurais Artificiais do tipo Perceptron Multicamadas para realizar as regressões para os dois cenários. O Modelo Out-Dez apresentou bons resultados, com coeficientes de Nash-Sutcliffe e Kling-Gupta de 0,64 e 0,71, respectivamente, para a fase de teste. Já o Modelo Jan-Abr, apesar de retornar um coeficiente de Nash-Sutcliffe menor, de 0,56, também apresentou um desempenho satisfatório, com Kling-Gupta de 0,73. Deste modo, os modelos constituem ferramentas que podem ser de grande valia para a operação da usina e para o planejamento do setor hídrico local.

Palavras-chave: Previsão de vazão. Rede Neural Artificial. Índice Climático. Usina Hidrelétrica de Boa Esperança.

Seasonal Streamflow Forecast for the Hydroelectric Power Plant of Boa Esperança-PI using Artificial Neural Networks

ABSTRACT

Studies presenting climatological forecasts have grown in importance, as the increase in the demand for water and energy creates a need to obtain information about the future behavior of natural sources. This paper presents two models of forecasting the average streamflow of the Parnaíba River, at the Boa Esperança Hydroelectric Power Plant, for the periods from October to December and from January to April, times that present the highest average values for this hydrological variable on site. As predictors, climatic indices related to sea surface temperature were used, which were chosen through the analysis of teleconnections already known in the literature and the correlations calculated between the observed streamflows and the average values of the indices with different lags. Then, Artificial Neural Networks of Multilayer Perceptrons type were built to perform the regressions for these two scenarios. The Oct-Dec Model showed good results, with Nash-Sutcliffe and Kling-Gupta coefficients of 0.64 and 0.71, respectively, for the test phase. The Jan-Apr Model, in spite of returning a smaller Nash-Sutcliffe coefficient, of 0.56, also presented a satisfactory performance, with Kling-Gupta of 0.73. In this way, the models are tools that can be of great value for the operation of the plant and for the planning of the local water sector.

Keywords: Streamflow Forecast. Artificial Neural Network. Climate Index. Boa Esperança Hydroelectric Power Plant.

Introdução

O nordeste brasileiro é conhecido por ser uma região bastante populosa, onde predomina o clima semiárido. Essas condições fazem com que seja necessário um cuidado especial no manejo dos recursos hídricos da região, incentivando estudos que auxiliam na avaliação de sistemas e no combate à escassez de água (Araujo, Esquerre e Sahin, 2019). Nesse contexto, trabalhos que contribuem com o gerenciamento do setor hídrico local têm crescido em relevância, como aqueles que desenvolvem mapas de risco e diretrizes hidrológicas para a governança da água (Araújo, Mamede e Lima, 2018; Cordão et al., 2020), além de estudos que focam na análise da disposição dos reservatórios e dos parâmetros de qualidade (Nascimento et al., 2019; Souza et al., 2020).

Além dos usos relacionados ao abastecimento urbano, industrial e irrigação, alguns corpos hídricos do nordeste brasileiro são aproveitados na geração de energia elétrica. Dessa forma, têm sido realizados estudos no âmbito de investigar o comportamento das séries temporais de chuvas e vazões nas localidades das usinas hidrelétricas, bem como os possíveis impactos na geração de energia futura causados pelas mudanças climáticas (Silva et al., 2018; Perera e Hathnayake, 2019; da Silva et al., 2021). Uma possível abordagem é a elaboração de modelos de previsão climática sazonal das variáveis hidrológicas da região.

As previsões climáticas sazonais têm se tornado cada vez mais importantes no processo de tomada de decisão, tanto por parte das companhias de água como pelas usinas hidrelétricas. O constante aumento da demanda de água e de energia estabelece um cenário onde as informações sobre a disponibilidade futura desses recursos se tornam fundamentais. Com base nisso, diferentes modelos de previsão sazonal de chuvas (Hawthorne et al., 2013; Ramu et al., 2017; Bagirov e Mahmood, 2018; Tuel e Eltahir, 2018; Dai, Cheng e Lu, 2020) e vazões (Souza Filho e Lall, 2003; Block et al., 2009; Córdoba-Machado et al., 2016; Araújo et al., 2020; Quinn et al., 2021) têm sido construídos nos últimos anos, à medida que a relevância desse tipo de estudo cresce.

A previsão de vazões e a sua confiabilidade estão relacionadas ao eficiente gerenciamento dos recursos hídricos, que por sua vez, afeta diretamente o desenvolvimento econômico da região (Araújo, Dantas Neto e Souza Filho, 2015). Um modelo de previsão de vazões, apesar de sua utilidade, possui uma complexa construção, tratando-se de um problema multivariado com

diversas incertezas associadas ao processo. Para esse tipo de análise, costuma-se utilizar modelos climáticos dinâmicos ou estatísticos. Os métodos dinâmicos se baseiam na integração de modelos climáticos e hidrológicos, enquanto os métodos estatísticos utilizam registros históricos de observação da variável prevista e de preditores climáticos relevantes, empregando diferentes técnicas de regressão (Souza Filho e Lall, 2004; Araújo et al., 2020).

Variações interanuais na precipitação, e consequentemente na vazão dos rios, especialmente em regiões tropicais e subtropicais do mundo, estão diretamente relacionadas as oscilações oceânicas e atmosféricas (Sen, Altunkaynak e Özger, 2004). Aproveitando dessas informações climáticas, modelos estatísticos de previsão de vazões têm sido propostos em diversos estudos, comprovando que o uso de índices climatológicos como variáveis explicativas em modelos matemáticos permite explicar regimes de vazões interanuais (Silveira et al., 2017; Kim et al., 2019; Uvo, Foster e Olsson, 2021).

Além do uso de métodos estatísticos, algoritmos de aprendizado de máquina têm sido amplamente utilizados no desenvolvimento de modelos de previsão climática, empregando Regressão por Vetores de Suporte, processos Gaussianos e Redes Neurais Artificiais (RNA) (Pour, Wahab e Shahid, 2020; Essenfelder et al., 2020). As RNAs são ferramentas poderosas e que são comumente utilizadas na modelagem de fenômenos complexos, multivariados e não lineares. Essas se apresentam como estruturas inspiradas nas redes neurais do cérebro humano, contendo vários nós conectados, chamados neurônios artificiais. Esses, por sua vez, são responsáveis por receber informações externas e propagá-las para outros neurônios artificiais, transmitindo dados de forma não linear. Este método conta com diversos algoritmos de aprendizagem, que aprimoram os resultados obtidos após o estímulo com informações externas (Chen, Lu e He, 2020). Vários estudos recentes que empregaram o uso dessa ferramenta para previsão climática podem ser citados: De et al. (2011), Chao et al. (2020), Canchala et al. (2020), Araújo et al. (2020), entre outros.

Desse modo, presumindo que existem índices climáticos que apresentam correlações com as variáveis hidrológicas da bacia do Rio Parnaíba, o presente trabalho idealizou como objetivo desenvolver um modelo de previsão sazonal de vazões para o rio, na altura da Usina Hidrelétrica

de Boa Esperança (UHBE). Assim, utilizando os índices climáticos com maiores correlações para a região como dados de entrada do modelo, foram desenvolvidas duas RNAs com o intuito de calcular a vazão média futura para dois períodos distintos: outubro a dezembro, que corresponde a um período de pré-estação, e janeiro a abril, que coincide com a estação chuvosa do local. Dessa forma, a operação da usina poderá ser planejada em duas etapas, programando-se para os dois períodos que apresentam os maiores valores de vazão do rio.

Materiais e métodos

Área de estudo

O local escolhido para este estudo foi o Rio Parnaíba, na altura da UHBE, que faz parte do sistema Chesf (Companhia Hidrelétrica do São Francisco). A barragem está situada no município de Guadalupe, estado do Piauí, como mostra a Figura 1, e segundo a companhia, tem uma área de drenagem de 87.500 km² e capacidade máxima de 5.085.000.000 m³.

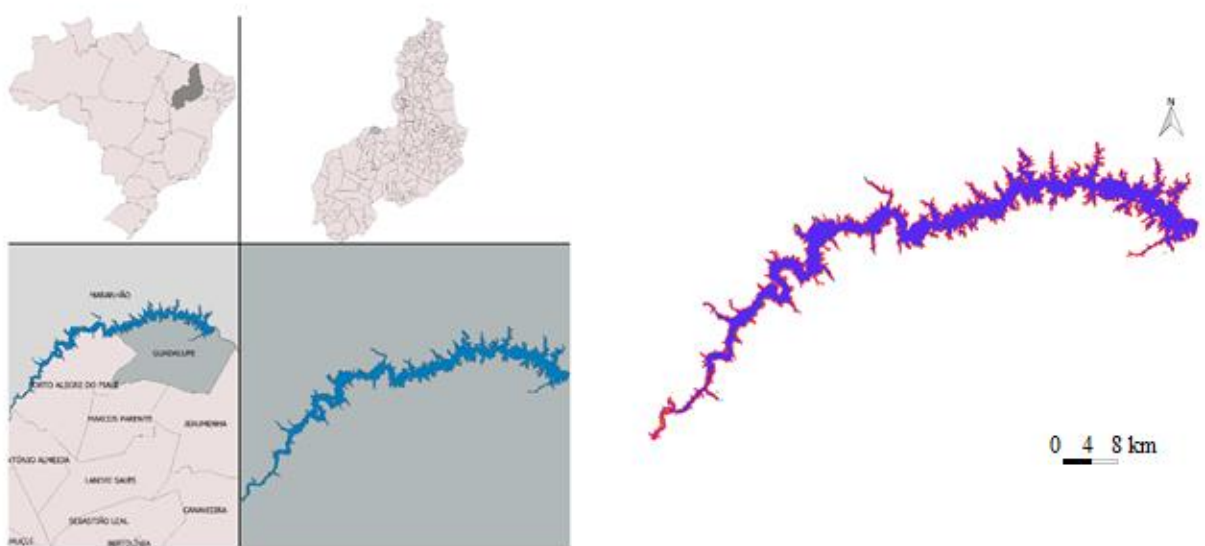


Figura 1. Localização da barragem da UHBE, apresentando a área de inundação.
Fonte: Adaptado do INPE, 2017

Para a dada região, a série temporal de vazões médias mensais foi construída em função de informações dos postos fluviométricos locais, datadas de 1931 a 2016, retiradas do banco de dados do Operador Nacional do Sistema Elétrico (ONS), como mostra a Figura 2. Na série, verifica-se que o período de janeiro a abril (Jan-Abr) corresponde à estação com maiores valores de vazões, apresentando uma média de 699 m³/s, com desvio padrão de 164 m³/s e coeficiente de variação de 23%. No entanto, nota-se que além destes quatro meses, há um período de pré-estação que antecede o ápice das vazões e que abrange os meses de outubro a dezembro (Out-Dez), com média de 401 m³/s, desvio padrão de 89 m³/s e coeficiente de

variação de 22%. No restante do ano, que abrange o intervalo de maio a setembro, a média calculada é de apenas 295 m³/s, o que revela a importância das outras duas estações.

Dessa forma, decidiu-se criar dois diferentes modelos de previsão: o Modelo Jan-Abr e o Modelo Out-Dez. Os dois modelos de previsão desenvolvidos foram tratados individualmente. A escolha dos índices climáticos utilizados como preditores e a determinação da estrutura e construção das RNAs foram realizadas de modo a retornar os melhores resultados para cada caso, de forma que se permitiu adotar diferentes índices e estruturas para cada um.

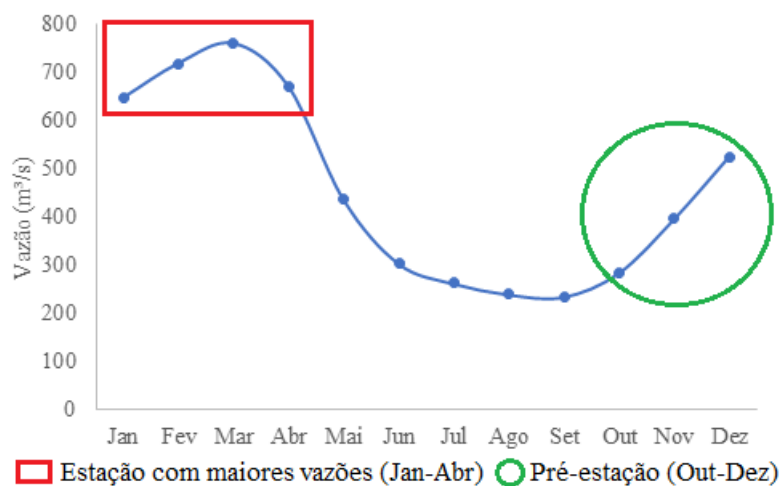


Figura 2. Média mensal das vazões a montante da UHBE, indicando os períodos de interesse para os modelos de previsão desenvolvidos.

Fonte: Elaborado pelos autores, com base nos dados do ONS.

A elaboração de dois modelos distintos, prevendo a vazão média para dois períodos diferentes do ano, permite que seja verificada a possibilidade de que o aumento das vazões nestas duas épocas tenha origens físicas diferentes, já que as correlações com os índices climáticos foram calculadas de forma independente. Além disso, a previsão em duas etapas possibilita a Chesf e aos operadores da UHBE planejar as operações futuras da usina em dois momentos distintos, ampliando o poder de predição e contribuindo nos processos de tomada de decisão.

Preditores Climáticos

Para a escolha dos índices climáticos adotados como preditores, utilizados como dados de entrada para os modelos de previsão de vazões, fez-se uso das séries temporais disponibilizadas pelo Laboratório de Ciências Físicas da *National Oceanic and Atmospheric Administration* (NOAA), encontrados no endereço eletrônico: <https://psl.noaa.gov/data/climateindices/list/>.

No processo de escolha dos preditores a serem utilizados, foram calculados os valores médios dos índices com intervalos de três meses e em seguida foram determinadas as correlações desses valores, com diferentes defasagens, com as médias das vazões de Out-Dez e de Jan-Abr. Para o Modelo Out-Dez, as correlações foram realizadas utilizando dados do mesmo ano para os índices e

para as vazões. Já para o Modelo Jan-Abr, as correlações calculadas consideraram os valores dos índices do ano anterior. As Tabelas 1 e 2 apresentam os melhores valores obtidos nas correlações, juntamente com o período do índice que resultou na melhor correspondência.

Dentre os preditores selecionados, a maioria se relaciona com anomalias na temperatura da superfície do mar (TSM) do oceano Atlântico, como o caso da Oscilação Atlântica Multidecadal (AMO), Índice Caribenho (CAR) e Índice do Atlântico Norte Tropical (TAN). Estudos apontam que anomalias de TSM no Atlântico estão associadas a migração da Zona de Convergência Intertropical (ZCIT) e podem conduzir a um aumento ou diminuição das chuvas no Nordeste brasileiro (Souza Filho e Lall, 2004). Outro índice adotado por apresentar uma correlação relevante foi o Niño 4. Vários estudos já assinalaram a importância das teleconexões formadas entre as regiões de El Niño e La Niña do Pacífico Sul e o Nordeste brasileiro (Souza Filho e Lall, 2003; Souza Filho e Lall, 2004; Block et al., 2009; Araújo et al., 2020). Por fim, também foi utilizado o WHWP, conhecido como Piscina Aquecida do Hemisfério Ocidental, que se refere as anomalias nas regiões do mar com temperatura mais alta que 28,5 °C que se formam a oeste da América Central e se expande para o leste, no Pacífico. Alguns estudos relacionam este índice a formação ciclones tropicais no Atlântico e a outros índices climáticos, como o AMO e o El Niño (Wang, Lee e Enfield, 2008; Park et al., 2018).

Tabela 1. Correlações dos preditores climáticos com a média das vazões (Out-Dez)

	AMO (Jan-Mar)	CAR (Fev-Abr)	Niño 4 (Abr-Jun)	TNA (Ago-Out)	WHWP (Jul-Set)
Vazão (Out-Dez)	-0,53	-0,53	-0,44	-0,38	-0,52

Tabela 2. Correlações dos preditores climáticos com a média das vazões (Jan-Abr)

	AMO (Set-Nov)	CAR (Jul-Set)	TNA (Set-Nov)	WHWP (Ago-Out)
Vazão (Jan-Abr)	-0,32	-0,41	-0,33	-0,43

Como mostram as Tabelas 1 e 2, os índices selecionados para desenvolver os modelos de regressão são praticamente iguais, com exceção do Niño 4, que foi removido do Modelo Jan-Abr. A maior correlação desse índice, referente a sua média de abril a junho, com as vazões médias de janeiro a abril do ano seguinte foi de -0,23, valor considerado baixo quando comparado as outras correlações obtidas. Além disso, após alguns testes, constatou-se que o Modelo Jan-Abr apresentava melhores resultados sem considerar esse preditor.

A constatação de que os índices climáticos que apresentaram as maiores correlações obtidas para os dois modelos foram semelhantes sugere que, de fato, os acréscimos de vazão nesses dois períodos possuem origens físicas em comum. No entanto, a decisão de construir dois modelos separados se manteve, pois apesar de se entender que o período de maior interesse é o de Jan-Abr, que apresenta os maiores valores de vazão, correlações mais fortes foram obtidas em Out-Dez. Além disso, se permanece a ideia de que a previsão feita em dois momentos distintos pode ser de maior valor estratégico.

Observando as defasagens dos índices que retornaram as melhores correlações nas Tabelas 1 e 2, nota-se que para o Modelo Out-Dez, a previsão poderá ser realizada apenas no mês de outubro, visto que serão utilizados dados deste mês para o índice TNA. Já para o Modelo Jan-Abr, os preditores com menor defasagem utilizados foram o AMO e o TNA, que retornaram melhores correlações com as vazões de janeiro a abril no período de setembro a novembro, o que permite ao modelo desenvolver uma previsão com no máximo um mês de antecedência.

Construção das RNAs

Após a seleção dos índices climatológicos a serem utilizados, suas séries temporais foram construídas e normalizadas, juntamente como os dados observados de vazão para os períodos. Em seguida foram desenvolvidos dois modelos de regressão nas formas de RNAs do tipo Perceptrons Multicamadas, com função de ativação sigmoide. As Equações simplificadas 1 e 2 resumem o formato das regressões.

$$Q_1 = f(\text{AMO}, \text{CAR}, \text{NINO4}, \text{TNA}, \text{WHWP}) \quad (1)$$

$$Q_2 = f(\text{AMO}, \text{CAR}, \text{TNA}, \text{WHWP}) \quad (2)$$

Onde Q_1 é a vazão média prevista para o Modelo Out-Dez e Q_2 a vazão média prevista para o Modelo Jan-Abr.

Para o desenvolvimento dos modelos, foi utilizado o pacote *neuralnet*, disponível em linguagem de programação R. O pacote permite treinar RNAs com retropropagação (backpropagation), retropropagação resiliente (*resiliente backpropagation*) ou um algoritmo globalmente convergente baseado na retropropagação resiliente (Anastasiadis, Magoulas e Vrahatis, 2005), o qual foi empregado neste trabalho.

As séries dos índices climatológicos e das vazões, utilizadas para os treinamentos e testes dos modelos, abrangem o período de 1950 a 2016, totalizando 67 anos de séries históricas. Para o treinamento da RNA do Modelo Out-Dez, foram utilizados 44 anos, escolhidos de modo que essa amostra fosse representativa quanto a variabilidade das vazões, restando 23 anos para a etapa de teste. Procedimento semelhante foi realizado para o Modelo Jan-Abr, mas apenas 22 anos foram utilizados na etapa de teste, pois o ano de 1950 foi utilizado apenas pelos dados dos índices que fazem a previsão do modelo para o ano seguinte. A Figura 3 apresenta as séries de vazões de Out-Dez e de

Jan-Abr, indicando os anos que foram utilizados como treino e como teste para os dois modelos construídos.

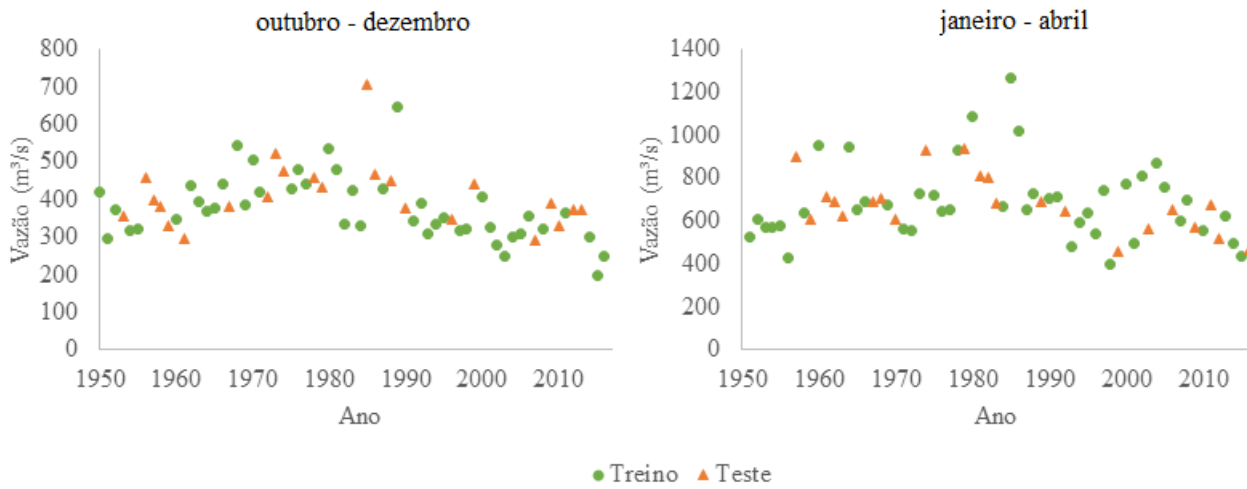


Figura 3. Vazões médias de outubro a dezembro e de janeiro a abril, indicando os anos que foram utilizados na fase de treinamento e na fase de teste durante o desenvolvimento das RNAs.

Fonte: Elaborado pelos autores, com base nos dados do ONS.

Após a construção dos dois modelos, utilizando os dados destinados para o treinamento, foi possível utilizar as RNAs para obter as previsões para as duas etapas, utilizando suas respectivas entradas. Dessa forma, entrando com os índices climáticos normalizados no modelo, as RNAs retornam previsões para as vazões, que foram desnormalizadas utilizando a série histórica.

As arquiteturas dos modelos, que se referem as quantidades de camadas e de neurônios das RNAs, foram determinadas de modo a retornar os melhores resultados para os coeficientes utilizados na análise de desempenho, os quais estão relacionados na seção abaixo.

Análise de Desempenho

Um coeficiente bastante utilizado para analisar a performance de modelos de previsão de variáveis hidrológicas é o coeficiente de Nash-Sutcliffe (Nash e Sutcliffe, 1970). A Equação 3 apresenta como é feito o cálculo deste parâmetro de eficiência.

$$NS = 1 - \frac{\sum(Q_o - Q_m)^2}{\sum(Q_o - \bar{Q}_o)^2} \quad (3)$$

Onde Q_o é a vazão observada, Q_m a vazão calculada pelo modelo e \bar{Q}_o a média das vazões observadas. Deste modo, caso NS assuma o valor um, significa dizer que o modelo prevê de forma “perfeita” o fenômeno, com os valores calculados

iguais aos observados. Quando o valor de NS é zero, o modelo apresenta valores tão bons quanto os previstos pela climatologia local. Já para valores negativos de NS, os valores de Q_m representam uma previsão pior do que a própria média da série histórica.

Outro coeficiente da literatura, que foi introduzido como um aprimoramento do NS, é o coeficiente de Kling-Gupta. Esse coeficiente utiliza uma função multiobjetivo na avaliação da performance do modelo, considerando três medidas estatísticas: a correlação de Pearson, a razão entre as médias e a razão entre os desvios. (Gupta et al., 2009; Pool, Vis e Seibert, 2018). As Equações 4, 5 e 6 apresentam como é feito o cálculo deste analisador de desempenho.

$$KG = 1 - \sqrt{(r - 1)^2 + (\beta - 1)^2 + (\alpha - 1)^2} \quad (4)$$

$$\beta = \frac{u_m}{u_o} \quad (5)$$

$$\alpha = \frac{\sigma_m}{\sigma_o} \quad (6)$$

Onde r é a correlação de Pearson entre os valores calculados e observados; u_m e u_o são as médias do modelo e das observações, respectivamente, e σ_m e σ_o são os desvios padrão do modelo e das observações, respectivamente. Assim como o NS, o KG igual a um representa um modelo “perfeito”, cujas previsões retornadas se apresentaram idênticas as observações.

Outro critério utilizado na análise de desempenho dos modelos foi o coeficiente de determinação R². Este pode ser calculado conforme a Equação 7.

$$R^2 = \frac{\text{Cov}(\text{Mod}, \text{Obs})}{\sigma_m \sigma_o} \quad (7)$$

Onde Cov(Mod,Obs) é a covariância entre os valores previstos pelo modelo e as observações.

Resultados e discussão

Modelo Out-Dez

Estudos recentes que apresentam algoritmos de otimização no método de escolha da arquitetura do Perceptron Multicamadas podem ser citados (Kapanova, Dimov e Sellier, 2016; Castro et al., 2017; Ramchoun et al., 2019). No entanto, a arquitetura do Modelo Out-Dez foi escolhida por um processo de tentativas, onde foram testadas diferentes configurações e selecionada aquela que retornou os melhores resultados quanto aos coeficientes de análise de desempenho. Um cuidado especial foi tomado para evitar estruturas

muito densas, que poderiam aumentar as chances de *overfitting* (Bansal et al., 2019).

Desse modo, a arquitetura escolhida para este modelo apresenta 5 nós como sinais de entrada, referentes aos índices climáticos, duas camadas intermediárias, onde a primeira apresenta quatro neurônios e a segunda dois, e um neurônio na camada de saída, relacionado com a vazão prevista. Para a estabilização do modelo, foram necessárias 1925 iterações, quando foi alcançado o critério de parada do algoritmo, que é o valor de 0,01 para a derivada parcial da função de erro, adotada como sendo a soma dos erros quadrados, aplicada no processo de atualização dos pesos sinápticos a cada iteração. A Tabela 3 apresenta os pesos sinápticos e os limiares (θ) obtidos para o Modelo Out-Dez. A Figura 4 ilustra a arquitetura da RNA desenvolvida no Modelo Out-Dez, com os pesos sinápticos e limiares determinados.

Tabela 3. Pesos sinápticos e limiares obtidos no Modelo Out-Dez
Camada de Entrada

		AMO	CAR	WHWO	Nino4	TNA	θ
1ª Camada Intermediária	1	1.36	0.14	3.13	-3.24	-2.19	2.03
	2	-15.98	-8.79	6.43	-4.78	7.33	-0.86
	3	-1.62	0.72	0.36	1.99	-0.36	0.04
	4	-2.18	1.99	0.60	3.98	0.10	-3.19
		1ª Camada Intermediária					
2ª Camada Intermediária		1	2	3	4	θ	
	1	1.64	-57.03	-1.33	0.02	-0.55	
	2	0.21	0.77	-1.25	1.99	0.38	
		2ª Camada Intermediária					
Camada de Saída		1	2	θ			
	Vazão	-0.85	-2.42	2.18			

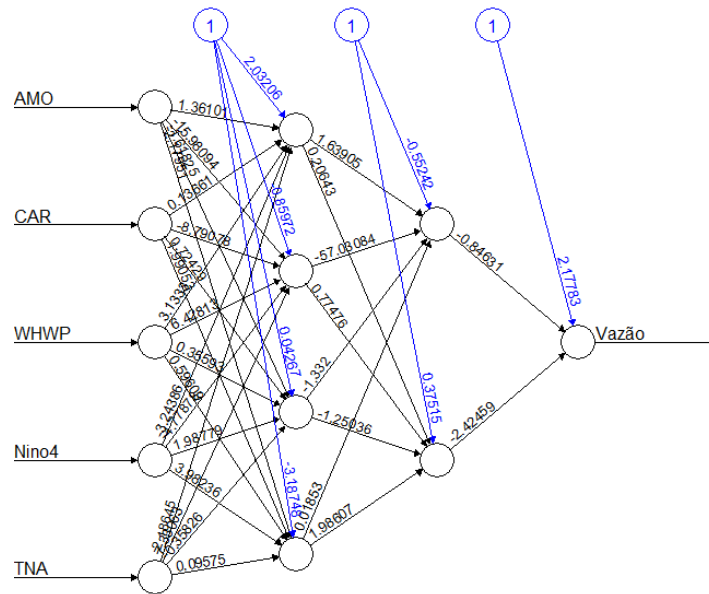


Figura 4. Representação da estrutura da RNA do Modelo Out-Dez, com os pesos sinápticos e limiares obtidos. Fonte: Elaborado pelos autores, utilizando a biblioteca neuralnet.

Após o ajuste, o Modelo Out-Dez foi utilizado para calcular as vazões para os dados de entrada utilizados no treinamento e, posteriormente, para os dados separados para o teste. O desempenho do modelo se mostrou levemente superior para os dados do treinamento, o que já era esperado, já que o ajuste foi realizado utilizando as informações dessa etapa. O NS calculado para os dados desta primeira etapa foi de 0,67, o que demonstra que o modelo apresenta uma performance consideravelmente superior à simples utilização da média das observações como previsão. O valor calculado para o KG nessa etapa foi de 0,71 e o coeficiente de determinação (R^2) calculado foi de 0,67.

Apesar de ser considerado um aprimoramento do NS, que segundo Santos, Thirel e Perrin (2018) subestima a variabilidade dos dados, o KG retornou um valor mais alto, sugerindo uma análise menos rigorosa dos resultados por esse coeficiente, ou mesmo que os valores previstos são ainda melhores do que o NS

aponta. Em seu estudo, Mizukami et al. (2019) comparou as duas fórmulas como funções objetivo na previsão de vazões de pico e notou que o KG retornou valores mais precisos, indicando que esse coeficiente tem um poder maior de avaliação.

Com relação ao coeficiente KG, Knoben, Freer e Woods (2019) apontam que esse não pode ser comparado diretamente com o NS, pois essa relação depende em parte do coeficiente de variação da série temporal. Além disso, diferente do NS, os autores colocam que valores acima de -0,41 para o KG já representam uma previsão superior ao uso da média das observações.

As Figuras 5 e 6 apresentam os resultados obtidos com o uso do Modelo Out-Dez para os dados da fase de treinamento. Na Figura 5, nota-se visualmente que a série construída com o modelo se comporta de forma semelhante à observada. Na Figura 6, a linha diagonal representa o que seria um modelo “perfeito”, com valores observados iguais aos calculados.




Figura 5. Comparação da série observada com a prevista pelo Modelo Out-Dez, para os dados da fase de treinamento.




Figura 6. Comparação das vazões observadas com as obtidas pelo Modelo Out-Dez, para os dados da fase de treinamento. A linha diagonal representa a faixa onde os valores observados e calculados apresentam o mesmo valor.

No intuito de incorporar um termo que considere a incerteza do modelo de previsão, admitiu-se que os resíduos calculados na fase de treinamento seguissem uma distribuição normal. Desse modo, para estabelecer um nível de confiança de 90% para o Modelo Out-Dez, o valor estimado para a vazão, em m^3/s , obedece a Equação 8. Análise semelhante foi feita no estudo Araújo et al. (2020), que utilizou intervalo de 95%.

$$Q_m - 81,52 \leq Q_{m90} \leq Q_m + 81,71 \quad (8)$$

O Modelo Out-Dez na fase de teste apresentou uma eficiência próxima ao do treinamento, retornando um valor de 0,64 para o NS, 0,71 para o KG e 0,62 para o R^2 . As Figuras 7 e 8 apresentam os resultados obtidos para o modelo nesta etapa, incorporando a margem de confiança estabelecida na Equação 8 na figura com as séries calculadas.

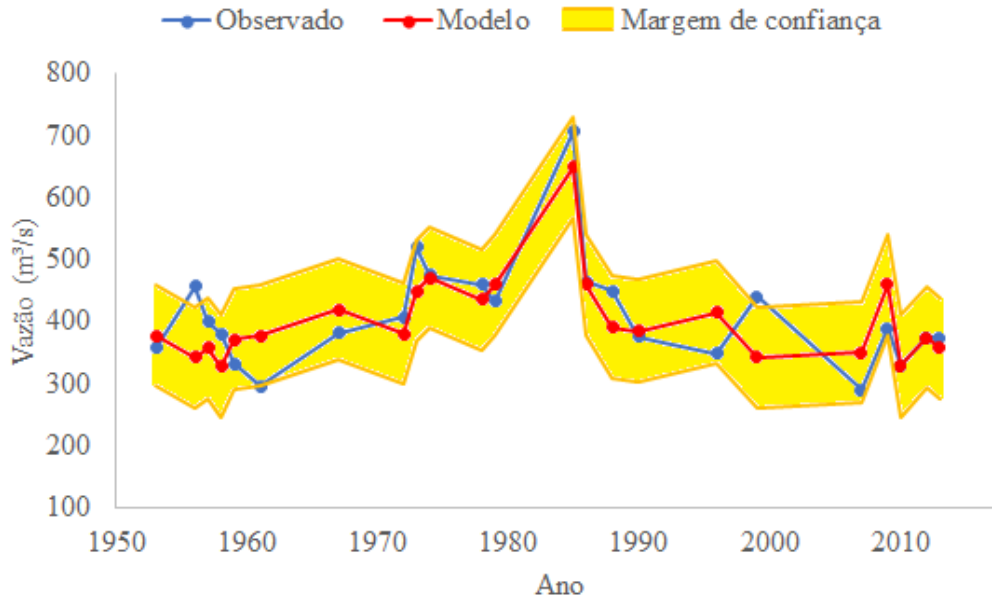


Figura 7. Comparação da série observada com a prevista pelo Modelo Out-Dez, para os dados da fase de teste, com incorporação da margem de confiança.

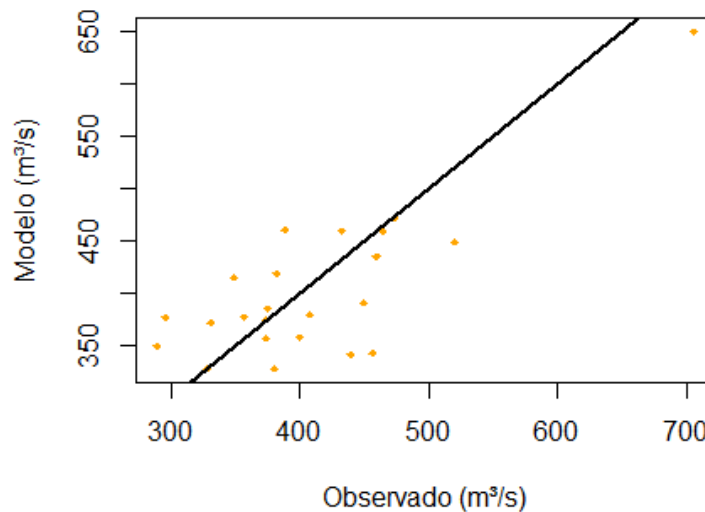


Figura 8. Comparação das vazões observadas com as obtidas pelo Modelo Out-Dez, para os dados da fase de teste. A linha diagonal representa a faixa onde os valores observados e calculados apresentam o mesmo valor.

Como foi explicado anteriormente, valores acima de zero para o coeficiente NS, em uma primeira análise, já podem ser considerados bons, por apresentar uma resposta com poder de previsão superior à média. Além disso, a performance do Modelo Out-Dez pode ser considerada boa, quando comparado o NS e R^2 obtidos com os de outros modelos de previsão de vazões da literatura (Silveira et al., 2017; Pulukuri, Keesara e Deva, 2018; Zhang et al., 2019; Araújo et al., 2020). De forma análoga, a boa qualidade do modelo pode ser observada comparando-se o KG encontrado com

Analisando a Figura 7, nota-se também que apenas dois anos dos testes, 1956 e 1999,

os de trabalhos semelhantes (Brocca et al., 2020; Krajewski, Ghimire e Quintero, 2020).

Em Horan et al. (2021), com o propósito de avaliar o desempenho de modelos hidrológicos, foram admitidos como bons os valores de NS calculados acima de 0,6, regulares os valores entre 0,2 e 0,6, e desempenho pobre para NSs menores que 0,2. Intervalos semelhantes foram utilizados nesse estudo para avaliar também o desempenho com base no KG. Nesse contexto, ambos os coeficientes apontaram para uma boa capacidade de previsão do Modelo Out-Dez.

apresentaram valores observados fora da margem de confiança, o que representa uma falha na

previsão em 8,7% da série, sugerindo que o modelo é fidedigno.

Modelo Jan-Abr

Uma análise semelhante foi feita para o Modelo Jan-Abr. A arquitetura empregada, e que retornou melhores resultados para as previsões, apresenta quatro nós de entrada, referentes aos índices climáticos, seis nós na camada intermediária e um na camada de saída, relativo à vazão. Estrutura parecida foi utilizada no trabalho de Tsakiri, Marsellos e Kapetanakis (2018) na previsão de cheias do Rio Mohawk, em Nova Iorque. Para os dados do treinamento, após 4000 iterações, o ajuste retornou os pesos sinápticos e

limiares apresentados na Tabela 4. A Figura 9 apresenta a estrutura da RNA construída para o Modelo Jan-Abr, com os pesos sinápticos e limiares da Tabela 4.

Assim como no Modelo Out-Dez, o Modelo Jan-Abr, após o ajuste, foi utilizado para calcular as vazões para o período utilizado no treinamento da RNA e posteriormente para o período de teste. O valor dos coeficientes NS, KG e R² para a primeira etapa foi de 0,56, 0,63 e 0,56, respectivamente. A queda do rendimento em relação ao outro modelo já era esperada, visto que melhores correlações haviam sido encontradas entre os índices climáticos e as vazões de outubro a dezembro, o que apontava que o Modelo Out-Dez seria capaz de retornar melhores previsões.

Tabela 4. Pesos sinápticos e limiares obtidos no Modelo Jan-Abr

		Camada de Entrada						
		AMO	CAR	WHWP	TNA	θ		
Camada Intermediária	1	0.73	0.12	0.91	0.18	-0.69		
	2	-2.76	1.31	-0.06	-2.03	0.71		
	3	1.17	-1.81	-2.87	1.83	0.14		
	4	22.63	-4.77	-4.09	1.01	-3.08		
	5	-26.38	21.78	42.09	6.56	-5.63		
	6	-5.78	26.52	2.79	7.85	-1.31		
		Camada Intermediária						
		1	2	3	4	5	6	θ
Camada de Saída	Vazão	1.01	1.50	1.24	0.60	0.57	-0.95	-1.24

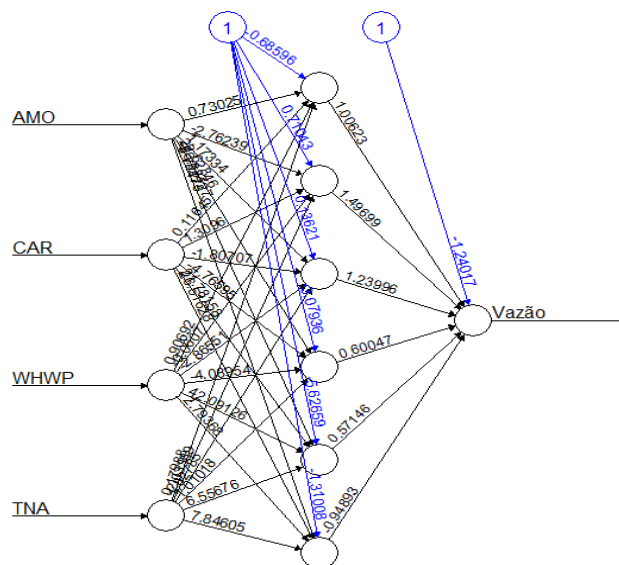


Figura 9. Representação da estrutura da RNA do Modelo Jan-Abr, com os pesos sinápticos e limiares obtidos. Fonte: Elaborado pelos autores, utilizando a biblioteca neuralnet.

As Figuras 10 e 11 apresentam os resultados do Modelo Jan-Abr para o período de treinamento. Assim como na Figura 5 e 7, a Figura 10 revela que a série construída com o modelo apresenta um comportamento semelhante a série observada. Na Figura 11, nota-se que os pontos

seguem de perto a tendência de crescimento da linha diagonal de 45°, a qual representa um modelo “perfeito”, sugerindo que as previsões são de boa qualidade.

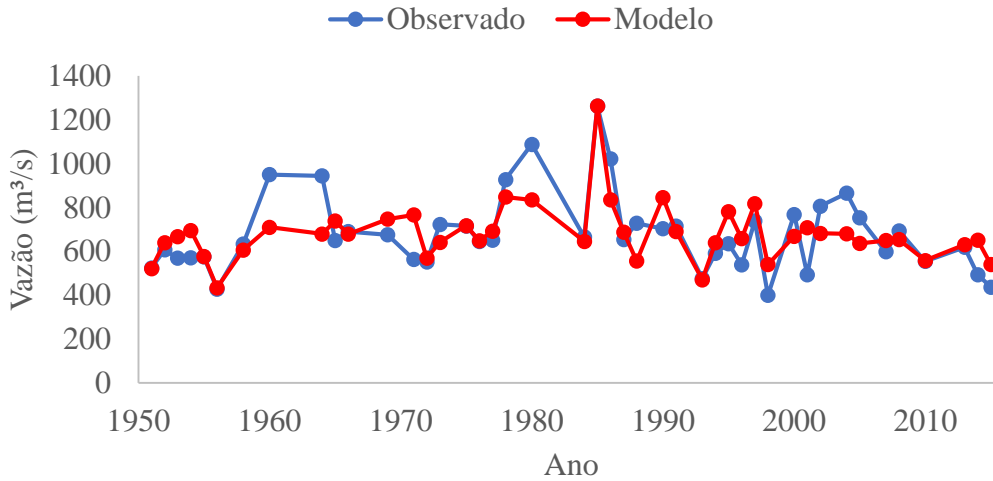


Figura 10. Comparação da série observada com a prevista pelo Modelo Jan-Abr, para os dados da fase de treinamento.




Figura 11. Comparação das vazões observadas com as obtidas pelo Modelo Jan-Abr, para os dados da fase de treinamento. A linha diagonal representa a faixa onde os valores observados e calculados apresentam o mesmo valor.

De forma semelhante ao Modelo Out-Dez e ao estudo de Araújo et al. (2020), os resíduos encontrados pelo Modelo Jan-Abr na fase de treinamento foram considerados como uma função de distribuição normal. Desse modo, para introduzir um elemento de incerteza na previsão e considerando as condições de normalidade dos resíduos, um nível de confiança de 90% foi utilizado para determinar um intervalo de valores para vazão estimada, conforme a Equação 9.

$$Q_m - 194,17 \leq Q_{m90} \leq Q_m + 193,82 \quad (9)$$

Com a Equação 9 e com a RNA estabelecida, o Modelo Jan-Abr foi aplicado para os dados do período de teste. As Figuras 12 e 13 apresentam os resultados obtidos nesta etapa.

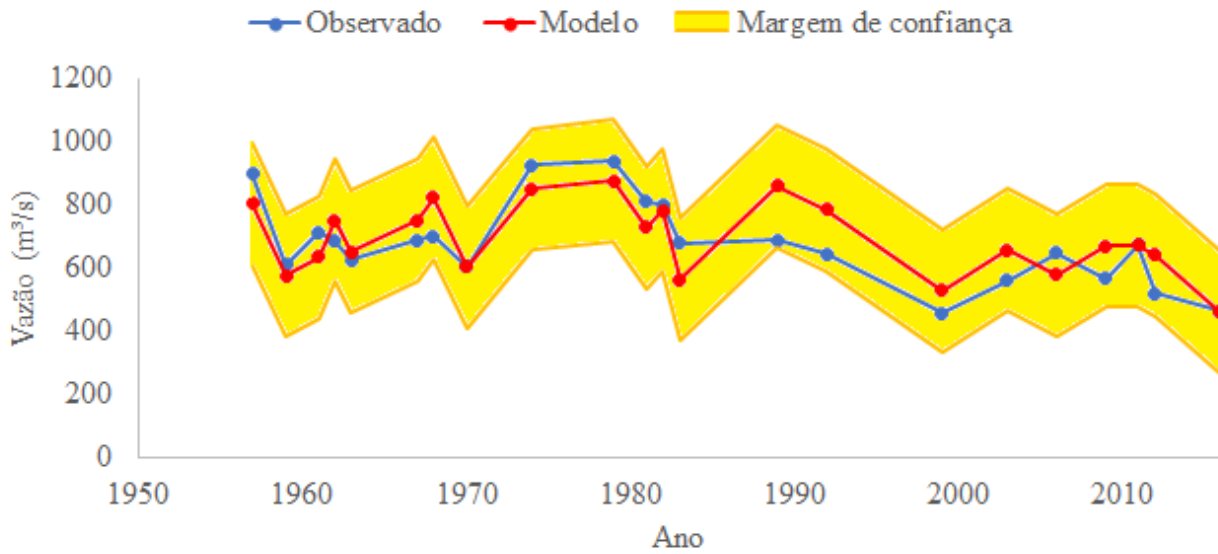


Figura 12. Comparação da série observada com a prevista pelo Modelo Jan-Abr, para os dados da fase de teste, com incorporação da margem de confiança.

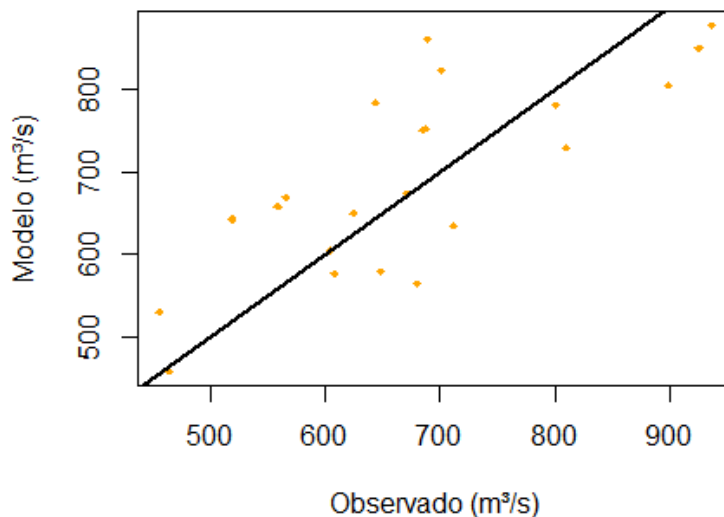


Figura 13. Comparação das vazões observadas com as obtidas pelo Modelo Jan-Abr, para os dados da fase de teste. A linha diagonal representa a faixa onde os valores observados e calculados apresentam o mesmo valor.

Os resultados obtidos pelo Modelo Jan-Abr, nessa segunda etapa, retornaram um coeficiente NS de 0,56, KG de 0,73 e um R^2 de 0,59, o que representa um desempenho até superior ao da fase de treinamento. Nota-se que, para o Modelo Jan-Abr, utilizando o critério de avaliação de Horan et al. (2021), a performance pode ser considerada regular, segundo o NS, e boa, segundo o KG. Além disso, comparando os valores obtidos na análise de desempenho com os de outros estudos de previsão de vazões, já citados, os resultados são suficientemente precisos para um modelo dessa categoria. Considerando essas ponderações e examinando que o comportamento da série simulada se assemelhou ao da observada, segundo

a Figura 12, entende-se que o modelo respondeu de forma satisfatória.

Analisando ainda a Figura 12, nota-se também que todos os anos da série observada se encontram dentro da margem de confiança estabelecida, o que respalda a capacidade de predição do modelo.

Conclusão

Modelos de previsão climática sazonal são de grande utilidade para a gestão dos recursos hídricos e planejamento do setor hidrelétrico. Tendo isso em vista, o presente trabalho teve como objetivo apresentar dois modelos de previsão de

vazões para o Rio Parnaíba, na altura da Usina Hidrelétrica de Boa Esperança, para os períodos de outubro a dezembro e janeiro a abril, utilizando índices climáticos como preditores e RNAs para as regressões.

Os resultados do Modelo Out-Dez indicaram um bom ajuste, com coeficiente NS de 0,64, KG de 0,71 e R² de 0,62 na fase de teste, valores esses considerados bons quando comparados com os obtidos por outros trabalhos com objetivos semelhantes. Nessa etapa, 21 observações dos 23 anos da série se encontraram na faixa de confiança estabelecida pelo método, o que aponta para o um bom desempenho do modelo construído.

O Modelo Jan-Dez, apesar de demonstrar uma performance inferior quanto aos coeficientes NS e R², calculados em 0,56 e 0,59, apresentou resultados satisfatórios, com um bom valor para o KG, calculado em 0,73. Além disso, com a utilização da margem de confiança construída no modelo, todos os valores de vazão das observações se encontraram internos aos limites estabelecidos.

Os resultados obtidos sugerem que os modelos são fidedignos, permitindo sua utilização para predição da vazão média nos dois períodos em análise, contribuindo como instrumento para auxiliar tanto na gestão do setor de águas local como na operação da usina hidrelétrica.

Agradecimentos

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela disponibilização e manutenção das bolsas de estudo, que tornam possíveis este tipo de pesquisa. Agradecem também a Universidade Federal do Ceará (UFC), pelo apoio institucional.

Referências

- Anastasiadis, A.D.; Magoulas, G.D.; Vrahatis, M. N. New globally convergent training scheme based on the resilient propagation algorithm. *Neurocomputing*, [s. l.], v. 64, p. 253-270, jan. 2005. <https://doi.org/10.1016/j.neucom.2004.11.016>.
- Araújo, C.B.C.; Dantas Neto, S. A.; Souza Filho, F. A. Previsão de vazões para o açude Orós/CE a partir de dados hidrometeorológicos utilizando perceptrons. *Revista Brasileira de Meteorologia*, [S.L.], v. 30, n. 1, p. 37-46, mar. 2015. <https://doi.org/10.1590/0102-778620140048>.
- Araújo, C.B.C.; Souza Filho, F.A.; Araújo Junior, L. M.; Silveira, C. S. Previsão Sazonal de Vazões para a Bacia do Orós (Ceará, Brasil) Utilizando Redes Neurais e a Técnica De Reamostragem dos K-vizinhos. *Revista Brasileira de Meteorologia*, [S.L.], v. 35, n. 2, p. 197-207, jun. 2020. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0102-7786351015>.
- Araújo, J.; Mamede, G.; Lima, B. Hydrological Guidelines for Reservoir Operation to Enhance Water Governance: application to the brazilian semiarid region. *Water*, [S.L.], v. 10, n. 11, p. 1628, 12 nov. 2018. MDPI AG. <http://dx.doi.org/10.3390/w10111628>.
- Araujo, W.C.; Esquerre, K.O.; Sahin, O. Building a System Dynamics Model to Support Water Management: a case study of the semiarid region in the brazilian northeast. *Water*, [S.L.], v. 11, n. 12, p. 2513, 28 nov. 2019. MDPI AG. <http://dx.doi.org/10.3390/w11122513>.
- Bagirov, A.M.; Mahmood, A.A Comparative Assessment of Models to Predict Monthly Rainfall in Australia. *Water Resources Management*, [S.L.], v. 32, n. 5, p. 1777-1794, 17 jan. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11269-018-1903-y>.
- Bansal, P.; Gupta, S.; Kumar, S.; Sharma, S.; Sharma, S. MLP-LOA: a metaheuristic approach to design an optimal multilayer perceptron. *Soft Computing*, [S.L.], v. 23, n. 23, p. 12331-12345, 21 jan. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00500-019-03773-2>.
- Block, P.J.; Souza Filho, F.A.; Sun, L.; Kwon, H. A Streamflow Forecasting Framework Using Multiple Climate And Hydrological Models. *Journal Of The American Water Resources Association (Jawra)*, [s. l.], v. 45, n. 4, p. 828-843, ago. 2009. <http://dx.doi.org/10.1111/j.1752-1688.2009.00327.x>.
- Brocca, L.; Massari, C.; Pellarin, T.; Filippucci, P.; Ciabatta, L.; Camici, S.; Kerr, Y.H.; Fernández-Prieto, D. River flow prediction in data scarce regions: soil moisture integrated satellite rainfall products outperform rain gauge observations in west africa. *Scientific Reports*, [S.L.], v. 10, n. 1, p. 1, 27 jul. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-020-69343-x>.
- Canchala, T.; Alfonso-Morales, W.; Carvajal-Escobar, Y.; Cerón, W. L.; Caicedo-Bravo, E. Monthly Rainfall Anomalies Forecasting for Southwestern Colombia Using Artificial Neural

- Networks Approaches. *Water*, [s. l] 12, no. 9: 2628. 2020 <https://doi.org/10.3390/w12092628>.
- Castro, W.; Oblitas, J.; Santa-Cruz, R.; Avila-George, H. Multilayer perceptron architecture optimization using parallel computing techniques. *Plos One*, [S.L.], v. 12, n. 12, p. 3, 13 dez. 2017. Public Library of Science (PLoS). <http://dx.doi.org/10.1371/journal.pone.0189369>.
- Chao, W.T.; Young, C.C.; Hsu, T.W.; Liu, W.C.; Liu, C.Y. Long-Lead-Time Prediction of Storm Surge Using Artificial Neural Networks and Effective Typhoon Parameters: Revisit and Deeper Insight. *Water*, [s. l], 12, n. 9: 2394, ago. 2020. <https://doi.org/10.3390/w12092394>.
- Chen, H.; Lu, F.; He, B. Topographic property of backpropagation artificial neural network: from human functional connectivity network to artificial neural network. *Neurocomputing*, [S.L.], 418, 200-210, dez. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2020.07.103>.
- Cordão, M.J.S.; Rufino, I.A.A.; Alves, P.B.R.; Barros Filho, M.N.M. Water shortage risk mapping: a gis-mcda approach for a medium-sized city in the brazilian semi-arid region. *Urban Water Journal*, [S.L.], v. 17, n. 7, p. 642-655, 8 ago. 2020. Informa UK Limited. <http://dx.doi.org/10.1080/1573062x.2020.1804596>.
- Córdoba-Machado, S.; Palomino-Lemus, R.; Gámiz-Fortis, S.R.; Castro-Díez, Y.; Esteban-Parra, M.J. Seasonal streamflow prediction in Colombia using atmospheric and oceanic patterns. *Journal Of Hydrology*, [S.L.], v. 538, p. 1-12, jul. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2016.04.003>.
- Dai, L.; Cheng, T.F.; Lu, M. Summer Monsoon Rainfall Patterns and Predictability over Southeast China. *Water Resources Research*, [S.L.], v. 56, n. 2, p. 1-55, fev. 2020. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2019wr025515>.
- De, S.S.; Chattopadhyay, G.; Paul, S.; Chattopadhyay, S.; Halder, D.K.. Forecasting the winter shower over India through a neurocomputing approach. *Journal Of Hydroinformatics*, [S.L.], 14, -522, 2 ago. 2011. IWA Publishing. <http://dx.doi.org/10.2166/hydro.2011.124>.
- Essenfelder, A.H.; Larosa, F.; Mazzoli, P.; Bagli, S.; Broccoli, D.; Luzzi, V.; Mysiak, J.; Mercogliano, P.; Valle, F.D. Smart Climate Hydropower Tool: a machine-learning seasonal forecasting climate service to support cost-benefit analysis of reservoir management. *Atmosphere*, [S.L.], v. 11, n. 12, p. 1305, 1 dez. 2020. MDPI AG. <http://dx.doi.org/10.3390/atmos11121305>.
- Gupta, H.V.; Kling, H.; Yilmaz, K.K.; Martinez, G.F. Decomposition of the mean squared error and NSE performance criteria: implications for improving hydrological modelling. *Journal Of Hydrology*, [S.L.], 377, 80-91, out. 2009. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2009.08.003>.
- Hawthorne, S.; Wang, Q.J.; Schepen, A.; Robertson, D. Effective use of general circulation model outputs for forecasting monthly rainfalls to long lead times. *Water Resources Research*, [S.L.], v. 49, n. 9, p. 5427-5436, set. 2013. American Geophysical Union (AGU). <http://dx.doi.org/10.1002/wrcr.20453>.
- Horan, R.; Gowri, R.; Wable, P.S.; Baron, H.; Keller, V.D.J.; Garg, K.K.; Mujumdar, P.P.; Houghton-Carr, H.; Rees, G. A Comparative Assessment of Hydrological Models in the Upper Cauvery Catchment. *Water*, [S.L.], 151, 1-25, 11 jan. 2021. MDPI AG. <http://dx.doi.org/10.3390/w13020151>.
- Instituto Nacional De Pesquisas Espaciais – INPE. Mapa do Reservatório Boa Esperança. Disponível em: http://geopro.crn.inpe.br/RH_reser_PI_boaespe_ranca.htm.
- Kapanova, K.G.; Dimov, I.; Sellier, J.M.. A genetic approach to automatic neural network architecture optimization. *Neural Computing And Applications*, [S.L.], v. 29, n. 5, p. 1481-1492, 28 jul. 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00521-016-2510-6>.
- Kim, T.; Shin, J.Y.; Kim, H.; Kim, S.; Heo, J.H. The Use of Large-Scale Climate Indices in Monthly Reservoir Inflow Forecasting and Its Application on Time Series and Artificial Intelligence Models. *Water*, [S.L.], v. 11, n. 2, p. 374, 21 fev. 2019. MDPI AG. <http://dx.doi.org/10.3390/w11020374>.
- Knoben, W.J.M.; Freer, J.E.; Woods, R.A. Technical Note: Inherent benchmark or not? comparing nash-sutcliffe and kling-gupta efficiency scores. *Hydrology And Earth System Sciences*, [S.L.], 23, 4323-4331, 25 out. 2019. Copernicus GmbH. <http://dx.doi.org/10.5194/hess-23-4323-2019>.
- Krajewski, W.F.; Ghimire, G.R.; Quintero, F. Streamflow Forecasting without Models. *Journal Of Hydrometeorology*, [S.L.], 21, 1689-1704, 1 ago. 2020. American

- Meteorological Society.
<http://dx.doi.org/10.1175/jhm-d-19-0292.1>.
- Mizukami, N.; Rakovec, O.; Newman, A.J.; Clark, M.P.; Wood, A.W.; Gupta, H.V.; Kumar, R. On the choice of calibration metrics for “high-flow” estimation using hydrologic models. *Hydrology And Earth System Sciences*, [S.L.], 23, 2601-2614, 17 jun. 2019. Copernicus GmbH. <http://dx.doi.org/10.5194/hess-23-2601-2019>.
- Nascimento, A.T.P.; Cavalcanti, N.H.M.; Castro, B.P.L.; Medeiros, P.H.A. Decentralized water supply by reservoir network reduces power demand for water distribution in a semi-arid basin. *Hydrological Sciences Journal*, [S.L.], 64, 80-91, 2 jan. 2019. Informa UK Limited. <http://dx.doi.org/10.1080/02626667.2019.1566728>.
- Nash, J.E.; Sutcliffe, J.V.. River flow forecasting through conceptual models part I — A discussion of principles. *Journal Of Hydrology*, [S.L.], 10, 282-290, abr. 1970. Elsevier BV. [http://dx.doi.org/10.1016/0022-1694\(70\)90255-6](http://dx.doi.org/10.1016/0022-1694(70)90255-6).
- National Oceanic And Atmospheric Administration – NOAA. Physical Sciences Laboratory. Climate Indices: Monthly Atmospheric and Ocean Time-Series. Disponível em: <https://psl.noaa.gov/data/climateindices/list/>.
- Operador Nacional Do Sistema Elétrico - ONS. Dados Hidrológicos/Vazões. Endereço eletrônico: <http://www.ons.org.br/>
- Park, J.H.; Kug, J.S.; Li, T.; Behera, S.K.. Predicting El Niño Beyond 1-year Lead: effect of the western hemisphere warm pool. *Scientific Reports*, [S.L.], v. 8, n. 1, p. 1-8, 8 out. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-018-33191-7>.
- Perera, A.; Rathnayake, U. Impact of climate variability on hydropower generation in an ungauged catchment: erathna run-of-the-river hydropower plant, sri lanka. *Applied Water Science*, [S.L.], v. 9, n. 3, 27 mar. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s13201-019-0925-9>.
- Pool, S.; Vis, M.; Seibert, J. Evaluating model performance: towards a non-parametric variant of the kling-gupta efficiency. *Hydrological Sciences Journal*, [S.L.], v. 63, n. 13-14, p. 1941-1953, 26 out. 2018. Informa UK Limited. <http://dx.doi.org/10.1080/02626667.2018.1552002>.
- Pour, S.H.; Wahab, A. K.A.; Shahid, S. Physical-empirical models for prediction of seasonal rainfall extremes of Peninsular Malaysia. *Atmospheric Research*, [S.L.], v. 233, p. 104720, mar. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2019.104720>.
- Pulukuri, S.; Keesara, V.R.; Deva, P. Flow Forecasting in a Watershed using Autoregressive Updating Model. *Water Resources Management*, [S.L.], 32, 2701-2716, 23 mar. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11269-018-1953-1>.
- Quinn, D.F.; Murphy, C.; Wilby, R.L.; Matthews, T.; Broderick, C.; Golian, S.; Donegan, S.; Harrigan, S. Benchmarking seasonal forecasting skill using river flow persistence in Irish catchments. *Hydrological Sciences Journal*, [S.L.], v. 66, n. 4, p. 672-688, 12 mar. 2021. Informa UK Limited. <http://dx.doi.org/10.1080/02626667.2021.1874612>.
- Ramchoun, H.; Idrissi, M.A.J.; Ghanou, Y.; Ettaouil, M. Multilayer Perceptron New Method for Selecting the Architecture Based on the Choice of Different Activation Functions. *International Journal Of Information Systems In The Service Sector*, [S.L.], v. 11, n. 4, p. 21-34, out. 2019. IGI Global. <http://dx.doi.org/10.4018/ijiss.2019100102>.
- Ramu, D.A.; Rao, S.A.; Pillai, P.A.; Pradhan, M.; George, G.; Rao, D. N.; Mahapatra, S.; Pai, D.S.; Rajeevan, M.. Prediction of seasonal summer monsoon rainfall over homogenous regions of India using dynamical prediction system. *Journal Of Hydrology*, [S.L.], v. 546, p. 103-112, mar. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2017.01.010>.
- Santos, L.; Thirel, G.; Perrin, C. Technical note: pitfalls in using log-transformed flows within the kge criterion. *Hydrology And Earth System Sciences*, [S.L.], v. 22, n. 8, p. 4583-4591, 30 ago. 2018. Copernicus GmbH. <http://dx.doi.org/10.5194/hess-22-4583-2018>.
- Şen, Z.; Altunkaynak, A.; Özger, M. El Niño Southern Oscillation (ENSO) Templates and Streamflow Prediction. *Journal Of Hydrologic Engineering*, [S.L.], v. 9, n. 5, p. 368-374, set. 2004. American Society of Civil Engineers (ASCE). [http://dx.doi.org/10.1061/\(asce\)1084-0699\(2004\)9:5\(368\)](http://dx.doi.org/10.1061/(asce)1084-0699(2004)9:5(368)).
- Silva, M.V.M.; Silveira, C.S.; Costa, J.M.F.; Martins, E.S.P.R.; Vasconcelos Júnior, F.C. Projection of Climate Change and Consumptive Demands Projections Impacts on Hydropower Generation in the São Francisco River Basin, Brazil. *Water*, [S.L.], v. 13, n. 3, p. 332, 29 jan.

2021. MDPI AG. <http://dx.doi.org/10.3390/w13030332>.
- Silva, W.L.; Xavier, L.N.R.; Maceira, M.E.P.; Rotunno, O.C. Climatological and hydrological patterns and verified trends in precipitation and streamflow in the basins of Brazilian hydroelectric plants. *Theoretical And Applied Climatology*, [S.L.], v. 137, n. 1-2, p. 353-371, 23 ago. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00704-018-2600-8>.
- Silveira, C.S.; Alexandre, A.M.B.; Souza Filho, F.A.; Vasconcelos Junior, F.C.; Cabral, Samuelson Lopes. Monthly streamflow forecast for National Interconnected System (NIS) using Periodic Auto-regressive Endogenous Models (PAR) and Exogenous (PARX) with climate information. *RBRH*, [S.L.], v. 22, p. 1-10, 2017. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/2318-0331.011715186>.
- Souza Filho, F.A.; Lall, U. Seasonal to interannual ensemble streamflow forecasts for Ceara, Brazil: applications of a multivariate, semiparametric algorithm. *Water Resources Research*, [S.L.], v. 39, n. 11, p. 1-13, nov. 2003. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2002wr001373>.
- Souza Filho, F.A.; Lall, U. Modelo de Previsão de Vazões Sazonais e Interanuais. *RBRH*, [s. l.], v. 2, n. 9, p. 61-74, jun.2004. <http://dx.doi.org/10.21168/rbrh.v9n2.p61-74>.
- Souza, S.O.; Lima, G.R.R.; Alencar, F.K.M.; Batista, A.C.O.N.; Silva, F.J.A. Assessment of water quality for industrial and irrigation purposes based on ionic indices in the Sítios Novos Reservoir, Ceará, Brazil. *Sustainable Water Resources Management*, [S.L.], v. 6, n. 5, 21 set. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s40899-020-00452-1>.
- Tuel, A.; Eltahir, E.A.B. Seasonal Precipitation Forecast Over Morocco. *Water Resources Research*, [S.L.], v. 54, n. 11, p. 9118-9130, nov. 2018. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2018wr022984>.
- Tsakiri, K.; Marsellos, A.; Kapetanakis, S. Artificial Neural Network and Multiple Linear Regression for Flood Prediction in Mohawk River, New York. *Water*, [S.L.], v. 10, n. 9, 29 ago. 2018. MDPI AG. <http://dx.doi.org/10.3390/w10091158>.
- Uvo, C.B.; Foster, K.; Olsson, J. The spatio-temporal influence of atmospheric teleconnection patterns on hydrology in Sweden. *Journal Of Hydrology: Regional Studies*, [S.L.], v. 34, abr. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.ejrh.2021.100782>.
- Wang, C.; Lee, S.K.; Enfield, D.B. Atlantic Warm Pool acting as a link between Atlantic Multidecadal Oscillation and Atlantic tropical cyclone activity. *Geochemistry, Geophysics, Geosystems*, [S.L.], v. 9, n. 5, p. 1-17, maio 2008. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2007gc001809>.
- Zhang, Q.; Li, Z.; Snowling, S.; Siam, A.; El-Dakhkhni, W. Predictive models for wastewater flow forecasting based on time series analysis and artificial neural network. *Water Science And Technology*, [S.L.], v. 80, n. 2, p. 243-253, 15 jul. 2019. IWA Publishing. <http://dx.doi.org/10.2166/wst.2019.263>.