

AVALIAÇÃO DE MODELOS DE SÉRIES TEMPORAIS PARA MODELAGEM E PREVISÃO DE VAZÕES MÉDIAS MENSAS EM BACIA HIDROGRÁFICA DO PANTANAL

Thaiana **Todeschini**¹, Frederico Carlos Martins de **Menezes Filho**²

(1 – Universidade Federal de Mato Grosso (UFMT), Programa de Pós-graduação em Recursos Hídricos, thaiana.todeschini@outlook.com, <https://orcid.org/0000-0003-4444-3754>; 2 – Universidade Federal de Viçosa (UFV), Campus Rio Paranaíba, Instituto de Ciências Exatas e Tecnológicas, frederico.menezes@ufv.br, <https://orcid.org/0000-0003-4874-0254>)

Resumo: As estratégias de previsão e gestão dos recursos hídricos são cada vez mais urgentes devido à crescente demanda por água, impulsionada pelo rápido crescimento populacional e desenvolvimento econômico. A previsão de vazão é um instrumento para garantir a segurança hídrica e mitigar impactos na agricultura, geração de energia e consumo humano. Enquanto os modelos determinísticos baseados no balanço hídrico exigem ampla disponibilidade de dados e esforços para calibração, os modelos estocásticos da classe ARIMA, oferecem alternativas eficazes para a previsão de séries temporais em locais com baixa disponibilidade de dados. O SARIMA é adequado para séries com padrões sazonais, enquanto o SARIMAX se destaca por incluir variáveis explanatórias, dentre elas precipitação e temperatura, que podem melhorar significativamente a precisão das previsões. Neste estudo, foram desenvolvidos modelos sazonais da classe ARIMA para a previsão de vazões médias mensais, considerando como variáveis explanatórias a precipitação e a temperatura. Tais modelos apresentaram excelente capacidade de capturar as oscilações da série temporal. A inclusão da temperatura melhorou o desempenho dos modelos SARIMAX em comparação ao modelo SARIMA, considerando apenas a vazão. No entanto, entre os modelos que incluíram precipitação, a temperatura não apresentou impacto significativo, com desempenhos similares. Destaque para o modelo SARIMAX, que, ao incluir precipitação, alcançou um desempenho superior na etapa de treino, RMSE de 13,20, NSE de 0,77 e PBIAS de -0,3% e para o teste, RMSE de 19,49, NSE de 0,95 e PBIAS DE 6,0%, para um horizonte de 9 meses. Esses resultados reforçam a relevância da

inclusão de variáveis climáticas na modelagem, demonstrando o potencial do modelo como uma ferramenta estratégica de apoio à tomada de decisões na gestão de recursos hídricos.

Palavras-chave: Modelos estocásticos. SARIMA. SARIMAX.

EVALUATION OF TIME SERIES MODELS FOR MODELING AND FORECASTING MONTHLY AVERAGE STREAMFLOWS IN THE PANTANAL RIVER BASIN

Abstract: Forecasting and management strategies for water resources are increasingly urgent due to the growing demand for water, driven by rapid population growth and economic development. Streamflow forecasting is a key tool to ensure water security and mitigate impacts on agriculture, energy generation, and human consumption. While deterministic models based on water balance require extensive data availability and significant calibration efforts, stochastic models of the ARIMA class offer effective alternatives for time series forecasting in data-scarce locations. SARIMA is suitable for series with seasonal patterns, while SARIMAX stands out by incorporating explanatory variables, such as rainfall and temperature, which can significantly improve forecast accuracy. In this study, seasonal ARIMA class models were developed for forecasting monthly average streamflow, considering rainfall and temperature as explanatory variables. These models demonstrated excellent capacity to capture the temporal series fluctuations. The inclusion of temperature improved the performance of SARIMAX models compared to SARIMA models using only flow data. However, among models that included rainfall, temperature showed no significant impact, with similar performances. Notably, the SARIMAX model that incorporated rainfall achieved superior performance in the training stage, with RMSE of 13.20, NSE of 0.77, and PBIAS of -0.3%, and in the testing stage, RMSE of 19.49, NSE of 0.95, and PBIAS of 6.0%, for a 9-month forecast horizon. These results reinforce the relevance of including climatic variables in modeling, demonstrating the potential of the model as a strategic decision-support tool for water resource management.

Keywords: Stochastics models. SARIMA. SARIMAX.

EVALUACIÓN DE MODELOS DE SERIES TEMPORALES PARA LA MODELACIÓN Y PRONÓSTICO DE CAUDALES MEDIOS MENSUALES EN UNA CUENCA HIDROGRÁFICA DEL PANTANAL

Resumen: Las estrategias de pronóstico y gestión de los recursos hídricos son cada vez más urgentes debido a la creciente demanda de agua, impulsada por el rápido crecimiento poblacional y el desarrollo económico. El pronóstico de caudales es una herramienta clave para garantizar la seguridad hídrica y mitigar impactos en la agricultura, la generación de energía y el consumo humano. Mientras que los modelos determinísticos basados en el balance hídrico requieren una amplia disponibilidad de datos y esfuerzos considerables de calibración, los modelos estocásticos de la familia ARIMA ofrecen alternativas eficaces para el pronóstico de series temporales en regiones con escasa disponibilidad de datos. El modelo SARIMA es adecuado para series con patrones estacionales, mientras que el SARIMAX se destaca por permitir la inclusión de variables explicativas, como la precipitación y la temperatura, que pueden mejorar significativamente la precisión de los pronósticos. En este estudio, se desarrollaron modelos estacionales de la clase ARIMA para el pronóstico de caudales medios mensuales, considerando como variables explicativas la precipitación y la temperatura. Estos modelos demostraron excelente capacidad para captar las oscilaciones de la serie temporal. La inclusión de la temperatura mejoró el desempeño de los modelos SARIMAX en comparación con el modelo SARIMA que consideró solo el caudal. Sin embargo, entre los modelos que incluyeron precipitación, la temperatura no presentó un impacto significativo, con desempeños similares. Destaca el modelo SARIMAX que, al incluir precipitación, alcanzó un desempeño superior en la etapa de entrenamiento, con RMSE de 13,20, NSE de 0,77 y PBIAS de -0,3%, y en la etapa de prueba, RMSE de 19,49, NSE de 0,95 y PBIAS de 6,0%, para un horizonte de predicción de 9 meses. Estos resultados refuerzan la relevancia de incluir variables climáticas en la modelización, demostrando el potencial del modelo como una herramienta estratégica de apoyo a la toma de decisiones en la gestión de recursos hídricos.

Palabras clave: Modelos estocásticos. SARIMA. SARIMAX.

1. INTRODUÇÃO

As estratégias de previsão e gestão dos recursos hídricos são cada vez mais urgentes devido à crescente demanda por água, impulsionada pelo rápido crescimento populacional e desenvolvimento econômico. Uma gestão adequada de recursos hídricos é essencial para garantir a segurança hídrica e o abastecimento das demandas por água (Siqueira, 2021).

Apesar dos avanços na modelagem hidrológica, as áreas do mundo mais vulneráveis carecem de previsões confiáveis e sistemas de alerta precoce (Nearing et. al., 2024). Isso destaca a urgência de aprimorar as estratégias de previsão para mitigar impactos adversos em áreas urbanas e setores essenciais, como agricultura, abastecimento de água, e geração de energia elétrica (Shah et al., 2023).

Tradicionalmente, os modelos físicos, baseados no balanço hídrico têm sido amplamente utilizados para simular a interação complexa entre precipitação, escoamento superficial, infiltração e evapotranspiração (Naganna et al., 2023). No entanto, tais modelos podem exigir grande disponibilidade de informações, tais quais plantas altimétricas, mapas pedológicos, além de dados de uso e cobertura do solo, precipitação e vazão, estando sujeitos às limitações quanto à disponibilidade destas informações (Nguyen et al., 2023).

Por outro lado, os modelos estocásticos representam uma abordagem probabilística para a previsão hidrológica, sem levar em consideração a relação entre os processos físicos ocorridos na bacia hidrográfica, tendo importância principal no processo de modelagem, a qualidade dos dados coletados. Tais modelos são baseados em eventos e podem não representar bem as dependências espaciais em sua formulação original (Brunner et al., 2021).

Os modelos Autoregressivos de Médias Móveis Integradas (ARIMA), introduzidos por Box e Jenkins na década de 1970 (Box & Jenkins, 1994; Hamza & Hassan, 2015), são amplamente utilizados na análise de séries temporais como ferramentas estatísticas para representar e capturar as características de dados gerados por processos estocásticos. Seus parâmetros podem ser ajustados para que o modelo seja convertido em variantes como modelos autorregressivos (AR), de médias móveis (MA) ou autorregressivos de médias móveis (ARMA) (Costa et al, 2023).

Dentre as extensões desses modelos, destacam-se o SARIMA e o SARIMAX, desenvolvidos para lidar, respectivamente, com séries temporais que apresentam características sazonais ou permitam a inclusão de variáveis regressoras ou exógenas.

A aplicação de modelos ARIMA para a previsão de vazões tem sido amplamente explorada ao longo dos anos, com destaque para o estudo pioneiro de Aguado (1982), que buscou prever as baixas vazões anuais do Rio Nilo, no Egito, utilizando esses modelos e obtendo resultados promissores. Outro estudo pioneiro e relevante foi o de Rao e Quillan (1982), ao aplicar os modelos ARIMA na previsão de vazões médias mensais, no Rio Chattahoochee, nos EUA, apresentando excelente desempenho preditivo.

No Brasil, diversos estudos têm aplicado modelos ARIMA para previsões hidrológicas, Bayer, Castro & Bayer (2012) utilizaram um modelo SARIMA para previsões de vazões médias mensais, com horizonte de seis meses, na bacia hidrográfica do Rio Potiribu (RS). Consoante os mesmos autores, o referido trabalho propiciou bons resultados mesmo sem o uso de variáveis explicativas como a precipitação ou evapotranspiração.

De modo semelhante, Figueiredo & Blanco (2014) analisaram a previsão de vazões e níveis de água médios mensais para a bacia do Rio Tapajós (PA), utilizando modelos ARIMA para um horizonte de previsão de vinte e quatro meses. Apesar dos resultados satisfatórios nas etapas de calibração e validação, os autores recomendaram cautela para o período de cheia, visto que grande parte dos eventos extremos foi subestimada.

Na sequência, Pinto et. al (2015), analisaram os modelos SARIMA para previsões médias mensais para o rio Doce em Colatina (ES), considerando um horizonte de vinte quatro meses. Apesar dos bons resultados obtidos, os referidos autores recomendaram o uso futuro de variáveis meteorológicas adicionais para o melhor entendimento do comportamento hidrológico do rio Doce.

Posteriormente, Bleidorn et al. (2019) aplicaram o modelo SARIMA na previsão de vazões médias mensais para o rio Jucu (ES), considerando um horizonte de 12 meses. Em virtude de uma crise hídrica sem precedentes na série temporal utilizada, as previsões foram divergentes dos valores observados, sendo sugerido pelos mesmos autores, a inclusão de variáveis explicativas como a precipitação e evaporação para melhoria dos modelos propostos.

Por fim, Duarte et al. (2019), ao utilizarem o modelo SARIMA para a previsão de vazões médias mensais em uma sub-bacia da região hidrográfica Tocantins-Araguaia, verificaram apesar do bom ajuste para os períodos de treino e teste, uma subestimativa das vazões de pico e uma boa aderência às vazões mínimas.

De forma análoga ao trabalho de Bleidorn et al. (2019), Caixeta, Menezes Filho & Fonseca (2021), ao aplicarem o modelo SARIMA para previsões de vazões médias mensais em uma sub-bacia do rio Paranaíba (MG), obtiveram resultados excelentes na etapa de treino e ruins na previsão; tendo como principal justificativa um cenário extremo de crise hídrica que ocorreu na região de estudo em 2014.

Em relação aos modelos SARIMAX, o trabalho de Costa et al. (2023) avançou nessa abordagem ao incluir dados de precipitação como variável regressora para a previsão de vazões

médias mensais em sub-bacia do Rio Paranaíba (MG), resultando num melhor desempenho do modelo frente ao modelo SARIMA.

Na mesma linha, Yonus & Hassan (2022) e Hosseinzadeh et al. (2023) ampliaram a complexidade do modelo ao incorporar tanto dados de precipitação quanto de temperatura, aprimorando a capacidade preditiva dos modelos.

No contexto do Estado de Mato Grosso, onde os conflitos pelo uso dos recursos hídricos se intensificam devido à expansão do agronegócio e ao rápido crescimento urbano, estudos têm buscado soluções eficazes para a previsão de vazão. Um exemplo é o trabalho de Almeida et al. (2020), que aplicaram o modelo SETAR, da classe autorregressiva, para analisar o comportamento e prever os níveis do Rio Cuiabá, utilizando exclusivamente dados de réguas fluviométricas. Os resultados demonstraram que o modelo foi eficiente na previsão dos níveis e revelaram um impacto direto das atividades do setor elétrico, evidenciado pelo aumento da cota mínima anual do rio no período pós-implantação da barragem, em comparação com o período anterior.

Diante desses desafios, torna-se fundamental considerar a crescente demanda por água nas mais diversas atividades, como abastecimento urbano, irrigação, dessedentação animal, geração de energia elétrica e transporte hidroviário, reforçando a necessidade de modelos preditivos mais robustos para subsidiar a tomada de decisão e minimizar os impactos dos conflitos hídricos (Peixoto; Soares & Ribeiro, 2021).

A expansão do agronegócio no Estado de Mato Grosso a partir do final da década de 70 se destacou na região sudeste do estado, especialmente nos municípios de Rondonópolis e Itiquira estendendo-se para áreas adjacentes (Coy; Barrozo & Souza, 2020). Neste cenário, encontra-se a Bacia Hidrográfica do Rio Itiquira (BHRI), pertencente à Bacia do Rio Paraguai, conhecida por abrigar o Pantanal, uma das maiores extensões de áreas alagadas do planeta (ANA, 2018).

A Bacia do Rio Paraguai (BHRP) que abarca a BHRI, passou por várias secas hidrológicas significativas em sua história, destacando-se a vulnerabilidade da bacia a déficits hídricos e níveis de água extremamente baixos. De 2020 a 2024, a BHRP passou por uma sequência de cinco anos secos consecutivos, com a seca mais severa já registrada ocorrendo em 2024 (Serviço Geológico do Brasil, 2024).

Dada a importância da gestão de recursos hídricos em regiões de expansão urbana e agrícola, especialmente devido ao impacto que essas atividades podem ter sobre ecossistemas

sensíveis, como o Pantanal, é fundamental buscar o equilíbrio entre as necessidades humanas e a preservação dos recursos hídricos. Nesse contexto, este estudo propôs o desenvolvimento de modelos sazonais da classe ARIMA para previsão de vazões médias mensais, incluindo variáveis explanatórias como a precipitação e a temperatura.

A escolha da precipitação e da temperatura do ar como variáveis explanatórias baseia-se em evidências de que a precipitação responde diretamente pela geração do escoamento superficial, enquanto a temperatura modula processos de evapotranspiração, infiltração e armazenamento, afetando tanto cheias quanto estiagens (Patterson et al., 2022).

2. Metodologia

Nessa seção serão detalhados a área de estudo, a base de dados, a explicação sobre os modelos selecionados, os cenários analisados e as métricas para avaliação de desempenho dos modelos desenvolvidos.


2.1. Procedimentos metodológicos

O estudo foi realizado na Bacia Hidrográfica do Rio Itiquira (BHRI), um dos contribuintes do Pantanal Mato-grossense, tendo como exutório a estação Fluviométrica Itiquira (6652000), localizada nas coordenadas 54°09' 3,96" W – 17°12'28,08" S, com área de contribuição de 2920 km² (Figura 1). O exutório está localizado dentro da área urbana do município de Itiquira. A área da bacia abrange uma das principais regiões agrícolas do Estado de Mato Grosso e está localizada em região de clima tropical.

De acordo com a classificação de Köppen-Geiger (Kotter et al., 2006), o clima da região é classificado como do tipo Aw. Esse tipo de clima apresenta estação chuvosa no verão, de outubro a abril, e nítida estação seca no inverno, de maio a setembro, sendo julho o mês mais seco. A precipitação média anual é de 1.858 mm, sendo janeiro o mês mais chuvoso com precipitação média de 312 mm e o mês mais seco, com precipitação média de 12,5 mm (ANA, 2024). A temperatura média é de 23,44°C, variando de 19,4°C a 27,8°C, consonante com os dados da plataforma ERA5 (Muñoz Sabater, 2019).

Em relação ao uso e ocupação da terra, a BHRI apresenta 25% de áreas agrícolas, 31% pastagem, 11% formação florestal, 24% cerrado, 5% de áreas úmidas e 4% de outros usos, abrangendo os municípios de Alto Araguaia, Alto Garças, Itiquira e Pedra Preta (Mapbiomas, 2022).

Figura 1 - Localização e delimitação da BHRI, estações pluviométricas e fluviométricas, e altimetria.



Fonte: Elaborado pelos autores (2024).

A partir do final da década de 1970, o crescimento do agronegócio em Mato Grosso concentrou-se principalmente na região sudeste, com destaque para os municípios de Rondonópolis e Itiquira, expandindo-se posteriormente para áreas adjacentes (Coy; Barrozo & Souza, 2020), iniciando assim a transformação no uso do solo na região.

2.1.2 Dados utilizados

Foram utilizados dados de médias mensais de precipitação e vazão, fornecidos pela Agência Nacional de Águas e Saneamento Básico (ANA) disponíveis através plataforma Hidroweb. Os dados de precipitação foram preenchidos utilizando o método da ponderação regional (Tucci, 2015) e posteriormente realizou-se a análise de consistência pelo método da Dupla-Massa, desenvolvido pelo United States Geological Survey (USGS) (Collischonn & Dornelles, 2013). Para maiores detalhes, consultar Todeschini e Menezes Filho (2024). A precipitação média da bacia foi obtida utilizando o método dos polígonos de Thiessen, que divide a área em zonas de influência de cada posto, assumindo a precipitação constante em cada subárea (Dante et al., 2022).

Foram utilizados dados mensais das séries históricas de vazão, obtidos da estação fluviométrica Itiquira (66520000) e de precipitações, obtidas das estações pluviométricas Itiquira (1754000), Alto Araguaia (1753000) e Alto Garças (1653004) para o período de janeiro de 1984 a dezembro de 2019, conforme a tabela 1. Para o treinamento dos modelos, foi utilizado o intervalo de janeiro de 1984 a dezembro de 2018, reservando-se o período de janeiro a dezembro de 2019 para a etapa de teste.

Tabela 1 - Informações das estações de monitoramento da BHRI.

Código	Nome	Tipo	Coordenadas Geográficas		Área de Drenagem (km ²)	Altitude (m)	Início do monitoramento
			Longitude	Latitude			
6652000	Itiquira	Fluviométrica	-54,1511°	-17,2077°	2920	484	Abril/1971
1754000	Itiquira	Pluviométrica	-54,1400°	-17,2077°	-	526	Outubro/1965
1753000	Alto Araguaia	Pluviométrica	-53,2194°	-17,3000°	-	659	Janeiro/1964
1653004	Alto Garças	Pluviométrica	-53,5336°	-16,9442°	-	564	Mai/1976

Fonte: Hidroweb (ANA) (2024).

Em virtude da ausência de dados de temperatura disponíveis de estações meteorológicas para o período analisado, utilizou-se a base de dados ERA5-Land Monthly Aggregated - ECMWF Climate Reanalysis (Muñoz Sabater, 2019). Para tal, os dados de temperatura média foram obtidos por meio do Google Engine, fornecendo o polígono da bacia hidrográfica em estudo. Foram considerados os dados climáticos mensais oriundos de reanálise, referentes ao período de janeiro de 1984 a dezembro de 2019.

Os dados de vazão e temperatura não apresentaram lacunas no período analisado. Entretanto, os dados de precipitação necessitaram de preenchimento, conforme Todeschini e Menezes Filho (2024).

2.1.2 Modelos de previsão

Os modelos Autorregressivos Integrados de Média Móveis (ARIMA), introduzidos por Box & Jenkins (1976), têm sido aplicados na análise de séries temporais como modelos estatísticos lineares para representar e capturar padrões em dados de séries temporais gerados por processos estocásticos (Bayer & Souza, 2010). Dada a possibilidade da sazonalidade presente nos processos hidrológicos, a versão sazonal dos modelos ARIMA, denominado

SARIMA (Sazonal Autorregressivo Integrado de Média Móveis) se apresenta como alternativa eficaz para capturar além das autocorrelações temporais, padrões sazonais característicos de variáveis ambientais (Duarte et al., 2019; Costa et al., 2023; Caminha et al., 2025).

O modelo SARIMA (p,d,q) (P,D,Q) tem a estrutura dada pela Equação 1, sendo caracterizado pelas ordens autorregressivas (p,P), ordens de diferenciação (d,D) e ordens de médias móveis (q,Q).

$$(1) \quad \phi(B)\Phi(B^S) (1 - B^S)^D (1-B)^d Z_t = \theta(B) \Theta(B^S) \varepsilon_t$$

Em que: S é a periodicidade sazonal, $\phi(B)$ é o polinômio autorregressivo, $\theta(B)$ é o polinômio da média móvel e ε_t é o termo de erro do modelo do AR sazonal. As equações 2 e 3 referem-se, respectivamente, à determinação do $\Phi(B^S)$ que é o parâmetro autorregressivo sazonal e $\Theta(B^S)$ que corresponde ao parâmetro da média móvel sazonal.

$$(2) \quad \Phi(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{S^2} - \dots - \Phi_p B^{Sp}$$

$$(3) \quad \Theta(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{S^2} - \dots - \Theta_p B^{Sp}$$

O modelo SARIMAX (Autorregressivo-Integrado Média Móvel Sazonal com variáveis exógenas) é uma abordagem estatística utilizada para prever valores futuros de séries temporais, combinando relações lineares de valores passados, variáveis exógenas e termos de erro. O mesmo é aplicado quando variáveis exógenas influenciam o processo estocástico, aprimorando o desempenho das previsões (Costa et al., 2023).

Assim como o modelo SARIMA descrito na Equação (1), o modelo SARIMAX geralmente é expresso pela ordem de seus parâmetros (p,d,q) (P,D,Q). Diferencia-se pela inclusão de um termo exógeno representado pela soma no lado direito, que modela a relação entre a sequência observada e o vetor de informações relativas à variável exógena St , conforme descrito na equação 4.

$$(4) \quad \phi(B)\Phi(B^S) (1 - B^S)^D (1 - B)^d Z_t = \theta(B) \Theta(B^S) \varepsilon_t + \sum_{i=1}^m \beta_{iSt,i}$$

Em que: β é um vetor de coeficientes relativos à variável exógena.

A identificação de modelos da família ARIMA é uma importante etapa da metodologia de Box e Jenkins (1976). Tal etapa exige a determinação das ordens nominais e sazonais (p,q,P,Q) e ordens de integração (d, D). Para isto, pode-se dispor da análise gráfica das funções

de autocorrelação (FAC) e autocorrelação parcial (PAFC), avaliando-se a presença das componentes sazonalidade e tendência nas series temporais. Outros critérios de seleção de modelos amplamente utilizados são os critérios de informações de Akaike (AIC) (Akaike, 1974), e o critério de informação bayesiano Schwarz's BIC (Schwarz, 1978).

O modelo mais adequado é aquele que apresenta o menor valor dos critérios de seleção. Após a avaliação de todos os modelos, as previsões foram obtidas com base no melhor modelo selecionado. O método AIC é definido pela equação 5:

$$(5) \quad AIC = 2(k) - 2\ln(L)$$

Em que: L é a estimativa de máxima verossimilhança e k é o número de parâmetros do modelo e n o número de observações da série.

O método BIC é definido pela equação 6:

$$(6) \quad BIC = (k) \ln(N) - 2\ln(L)$$

Em que: L é a estimativa de máxima verossimilhança, k é o número de parâmetros do modelo e N o número de observações da série.

Assim como no AIC, minimizar o BIC tem o objetivo de identificar o melhor modelo. O modelo escolhido pelo BIC é ou o mesmo escolhido pelo AIC ou um modelo com menos termos. Isso ocorre porque o BIC penaliza o número de parâmetros de forma mais rigorosa do que o AIC (Hyndman et al., 2024).

A seleção de modelos mais adequados para cada cenário foi realizada utilizando-se a função `auto.arima()` do pacote `forecast`. Este comando automatiza o processo de seleção, combinando testes de raiz unitária (teste KPSS), minimização do critério de informação de Akaike (AIC) e estimativa de máxima verossimilhança (MLE), como descrito por Hyndman & Athanasopoulos (2021). A ampla aplicação do `auto.arima()` reduz o tempo necessário para determinar as ordens ótimas dos modelos ARIMA, utilizando os critérios AIC ou BIC (Caixeta; Menezes Filho & Fonseca, 2021; Hyndman & Khandakar, 2008; Lee & Cho, 2022; Costa et al., 2023).

Importante destacar que para o ajuste de modelos da classe ARIMA, verificou-se a estacionariedade da série em estudo, bem como, de forma complementar das séries temporais relativas às variáveis exógenas, utilizando-se o teste de Dickey-Fuller (Said & Dickey, 1984).

2.1.3 Cenários analisados

O treinamento dos modelos foi realizado utilizando dados da estação fluviométrica Itiquira (código 66520000). Foram analisados diferentes cenários para a previsão de vazões médias mensais em horizontes de 3, 6, 9 e 12 meses. Esses cenários foram definidos com base nas variáveis explanatórias utilizadas, a saber:

Quadro 1 – Modelos e cenários estudados.

Modelo	Variáveis utilizadas	Sigla
1	Vazão média mensal (Q)	M1
2	Vazão média mensal (Q) e precipitação média mensal (P)	M2
3	Vazão média mensal (Q), precipitação média mensal (P) e temperatura média mensal (T)	M3
4	Vazão média mensal e temperatura média mensal	M4

Em todos os cenários, as vazões médias mensais registradas na estação fluviométrica Itiquira foram consideradas como a variável alvo. O modelo M1, por incluir apenas uma variável, foi modelado como SARIMA. Os demais modelos, por considerarem múltiplas variáveis, são enquadrados na classe SARIMAX.

2.1.4 Métricas de desempenho

A escolha de métricas de desempenho é fundamental para a avaliação de modelos, embora nenhuma métrica isolada seja capaz de capturar integralmente seus comportamentos. Mesmo o uso de múltiplas métricas pode deixar de refletir aspectos relevantes, sendo necessário adaptá-las aos objetivos do estudo. Por isso, é apropriado que a avaliação do desempenho seja feita com base em um conjunto mínimo de métricas complementares (Klotz et al., 2021).

Neste estudo a análise de desempenho dos modelos foi realizada por meio da utilização das métricas: Nash-Sutcliffe (NSE), Kling-Gupta (KGE), Viés Percentual (PBIAS), Raiz do Erro Médio Quadrático (RMSE) e Erro Médio Quadrático (MSE), descritos na Tabela 2.

O NSE é usado para avaliar o desempenho do modelo hidrológico em relação a um modelo de referência representado pela média de todas as observações de vazão. Tem hipersensibilidade a valores extremos (Ferreira; Paz & Barros, 2020) e é mais eficaz para a avaliação da qualidade do ajuste do que o coeficiente R^2 , que pode indicar um bom ajuste geral, mas não identifica erros sistemáticos (Costa et al., 2023).

O Kling-Gupta Efficiency (KGE) é integra três componentes fundamentais: correlação, viés e variabilidade entre os dados observados e simulados. O KGE foi proposto como uma alternativa mais eficiente ao NSE. Enquanto o NSE tende a favorecer a correlação em detrimento da variabilidade e do viés, podendo ocorrer superestimações, o KGE considera de

forma equitativa a correlação, o viés e a variabilidade nas simulações hidrológicas (Gupta et. al.,2009).

Tabela 2 - Métricas utilizadas para avaliar o desempenho de modelos.

Equação	Mínimo, máximo e ótimo	Unidade	Referência
$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_s)^2}{\sum_{i=1}^n (Q_{obs} - \bar{Q}_{obs})^2}$	$-\infty, 1, 1$	-	Wohling et al. (2013)
$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + \left(\frac{\bar{Q}_s}{\bar{Q}_{obs}} - 1\right)^2}$	$-\infty, 1, 1$	-	Wohling et al. (2013)
$PBIAS = 100 * \frac{\sum_i (Q_s - Q_{OBS})}{\sum_i Q_{OBS,i}}$	$-\infty, \infty, 1$	%	Jimeno-Saez et.al (2018)
$MSE = \frac{\sum_{i=1}^n (Q_s - Q_{OBS})^2}{n}$	$0, \infty, 0$	$(m^3/s)^2$	Legates & McCabe Junior (1999)
$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_s - Q_{OBS})^2}{n}}$	$0, \infty, 0$	m^3/s	Romanowicz et al. (2013)

Em que: Q_s = vazão simulada (m^3/s), Q_{obs} = vazão observada (m^3/s), n = quantidade de dados.

Fonte: Adaptada de Ferreira; Paz & Bravo (2020).

O PBIAS indica a relação entre a diferença média das vazões observadas e estimadas, normalizada pelo desvio padrão das vazões observadas (Ferreira; Paz & Barros, 2020). Mede a tendência média dos dados simulados de serem maiores (PBIAS positivo) ou menores (PBIAS negativo) do que os seus correspondentes observados (Safieq et al.,2014).

O MSE calcula a média da série temporal de erros quadrados, evitando a compensação de erros médios, mas dificulta a interpretação do valor da métrica por resultar em uma unidade $(m^3/s)^2$ sem significado físico (Ferreira; Paz & Barros, 2020). O RMSE supera a limitação de unidade do MSE ao aplicar a raiz sobre o MSE. É uma medida ponderada do erro, enfatizando desvios mais significativos entre valores observados e modelados. Favorece picos e eventos de magnitude mais alta, tornando-o sensível a grandes erros ocasionais (Ghabia et al.,2022).

Embora seja eficaz para avaliar o desempenho em vazões elevadas, a interpretação do RMSE pode variar em diferentes bacias hidrográficas devido à escala do conjunto de dados (Jimeno-Saez et al., 2018; Kim, et al., 2023). Prefere-se o RMSE ao MSE, pois é medido nas mesmas unidades dos dados originais, proporcionando uma representação mais realista do

tamanho de um erro "típico" (Dawson; Abrahart & See, 2007). Na Tabela 3, é apresentada a classificação do desempenho dos modelos de previsão de vazão, considerando três métricas: NSE, PBIAS e RMSE.

Em relação a qualificação da métrica MSE, quanto menor o valor, melhor é o desempenho do modelo (Mao et al., 2021).

A Tabela 3 apresenta a classificação do desempenho dos modelos, baseada nas métricas NSE, KGE, PBIAS e RMSE.

Tabela 3 - Classificação do desempenho de modelos com base nas métricas NSE, KGE, PBIAS e RMSE.

Métrica	Excelente	Bom	Satisfatório	Insatisfatório	Referência
NSE	$> 0,70$	$0,50 \leq \text{NSE} < 0,70$	$0,30 \leq \text{NSE} < 0,50$	$\leq 0,30$	Jimeno-Saez et al. (2018)
KGE	Próximo de 1			Próximo de 0	Katipoğlu et.al (2023)
PBIAS	$ \text{PBIAS} \leq 25$	$25 < \text{PBIAS} \leq 50$	$50 < \text{PBIAS} \leq 70$	$ \text{PBIAS} > 70$	Jimeno-Saez et al. (2018)
RMSE	$< 10\%$	10 a 20%	20 a 50%	$> 50\%$	Pant et al. (2022)

Fonte: Elaborado pelos autores (2024).

3. Resultados e discussão

A Tabela 4 apresenta as medidas descritivas das variáveis vazão, precipitação e temperatura, obtidas a partir de 432 observações, no período de janeiro de 1984 a dezembro de 2019. Essas medidas permitem uma análise abrangente do comportamento estatístico de cada variável.

Tabela 4 - Medidas descritivas das variáveis em estudo

Medida Descritiva	Vazão (m³/s)	Precipitação (mm)	Temperatura (°C)
Média	62,09	147,79	23,44
Erro padrão	1,32	5,84	0,06
Mediana	55,10	137,22	23,56
Desvio padrão	27,48	121,29	1,33
Variância da amostra ¹	755,30	14712,13	1,77
Curtose ²	1,68	-0,46	0,52
Assimetria ²	1,15	0,54	-0,08
Mínimo	23,60	0,00	19,38
Máximo	185,00	554,60	27,79

Legenda: ¹ Vazão média mensal: (m³/s)²; Precipitação média mensal: mm²; Temperatura média mensal: (°C)²; ² Curtose e Assimetria são adimensionais. Período considerado: janeiro de 1984 a dezembro de 2019.

Fonte: Elaborado pelos autores (2024).

A vazão apresentou média de 62,09 m³/s, com erro padrão de 1,32 m³/s, indicando boa precisão na estimativa da média. A mediana foi de 55,10 m³/s, próxima à média, enquanto o desvio padrão de 27,48 m³/s evidencia uma variabilidade considerável nos valores registrados. A assimetria positiva (1,15) e a curtose de 1,68 sugerem uma distribuição assimétrica à direita. Os valores variaram de 23,60 m³/s a 185,00 m³/s, com amplitude de 161,40 m³/s.

Para a precipitação, a média foi de 147,79 mm, com erro padrão de 5,84 mm e desvio padrão de 121,29 mm, refletindo grande variabilidade nos dados, possivelmente devido à sazonalidade característica dessa variável. A mediana foi de 137,22 mm, e os valores oscilaram de 0,00 mm a 554,60 mm.


A temperatura apresentou uma média de 23,44 °C, com erro padrão de 0,06 °C e desvio padrão de 1,33 °C, revelando menor dispersão dos dados em relação às outras variáveis. A mediana foi de 23,56 °C, próxima da média, e os valores variaram entre 19,38 °C e 27,79 °C, com amplitude de 8,42 °C.

De acordo com Naghetini & Pinto (2007), o coeficiente de correlação (r) refere-se a um coeficiente que satisfaz a desigualdade $-1 \leq r \leq 1$, correspondendo os extremos, -1 e 1 para associações perfeitas positiva e negativa, respectivamente, e o valor nulo para nenhuma associação. Barbetta (2006) classifica a correlação em função dos valores de r , em três intervalos, a saber: correlação forte para valores superiores a 0,70, correlação moderada para valores de r entre 0,30 e 0,70 e correlação fraca para valores inferiores a 0,30.

Vale ressaltar que uma associação positiva entre 2 variáveis, resultante de um alto valor para r , não implica uma relação causa-efeito (Naghetini & Pinto, 2007). Por isso, é importante analisar os gráficos de dispersão referentes às variáveis analisadas e não simplesmente confiar nos valores de correlação obtidos (Hyndman & Athanasopoulos, 2018).

Neste sentido, na Figura 2 apresentam-se os gráficos de dispersão entre as variáveis em estudo. Para a elaboração dos gráficos, os dados foram previamente normalizados. A correlação entre vazão e precipitação foi forte, com coeficiente $r = 0,78$, sugerindo uma relação positiva significativa entre essas variáveis. Já a correlação entre vazão e temperatura e precipitação e temperatura foram consideradas fracas, respectivamente com valores de r iguais a 0,01 e 0,23, indicando assim ausência de relação direta.

Figura 2 - Gráficos de correlação entre as variáveis em estudo. Vazão e precipitação (a), vazão e temperatura (b), precipitação e temperatura (c). Dados normalizados.




Fonte: Elaborado pelos autores (2025).

Tal aspecto observado de baixa correlação entre vazão e temperatura, bem como, entre a precipitação e temperatura, atenuam o problema da multicolinearidade.

Caso houvesse forte correlação entre as variáveis, a consideração das mesmas não incorreria em melhorias ao modelo a ser construído (Lana, 2023; Qin et al., 2024). Isso ocorre porque variáveis altamente correlacionadas tendem a competir entre si para explicar a variabilidade do fenômeno, o que reduz a importância relativa de uma delas devido à multicolinearidade (Correa; Silva & Matos, 2025).

A estacionariedade da série de vazões e de precipitações em relação à média e a variância observada na Figura 3, foi confirmada com o uso do teste de Dickey-Fuller (Said & Dickey, 1984), rejeitando-se a hipótese nula de não-estacionariedade com valor-p inferior a 0,01. Já para a série de temperaturas, aceitou-se a hipótese nula de não-estacionariedade com p-valor igual a 0,70; fato este que se justifica pela mudança de tendência observada na Figura 5, entre os anos de 1995 e 2000. Deste modo, a referida série foi diferenciada e confirmada sua estacionariedade pelo teste de Dickey-Fuller, para devida utilização como variável exógena nos modelos.


Figura 3 - Séries temporais de vazão, precipitação e temperatura mensais.



Legenda: Q – vazão média mensal em m³/s (estação 6652000); P – precipitação média mensal em mm (média mensal das estações 1754000, 1753000, 1653004); T – temperatura média mensal obtida pela plataforma ERA5; t – tempo. Período considerado: janeiro de 1984 a dezembro de 2019. **Fonte:** Elaborado pelos autores (2025).

A Figura 4 apresenta a decomposição aditiva das séries temporais de vazão, precipitação e temperatura do Rio Itiquira entre 1985 e 2019. A componente sazonal evidencia a variação anual, com aumento na vazão, precipitação e temperatura durante o verão (estação chuvosa) e redução no inverno (estação seca). A componente residual, destaca as variações aleatórias associadas a fatores imprevisíveis que influenciam o comportamento da vazão, precipitação e temperatura.


Figura 4 - Decomposição da série temporal de médias mensais de vazão (a), precipitação (b) e temperatura (c) em componente de sazonalidade, de tendência e de aleatoriedade.



Fonte: Elaborado pelos autores (2025).

A Figura 5 apresenta as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) para a série temporal de vazão. Esta análise é um passo importante para a identificação dos componentes do modelo ARIMA. Na ACF, observa-se na série, picos significativos nas primeiras defasagens, indicando que a série possui dependência temporal de curto prazo. Já a PACF mostra que a autocorrelação parcial decai rapidamente após a primeira defasagem. Ambos os gráficos indicam uma estrutura temporal bem definida, caracterizada por correlação predominante nas defasagens iniciais e um comportamento senoidal, refletido na alternância de sinais das defasagens. Os gráficos mostram autocorrelação significativa em múltiplos lags de 12, indicando a presença de sazonalidade.

Figura 5 - Funções de autocorrelação amostral (ACF) e de autocorrelação parcial amostral (PACF) da série de vazão.



Fonte: Elaborado pelos autores (2025).

Esse comportamento tem sido amplamente relatado em séries temporais de variáveis hidrometeorológicas. Barbosa et al. (2024) também observaram a alternância de sinais nas defasagens em séries de vazões e precipitações, embora sem um padrão senoidal bem definido. Da mesma forma, Menezes Filho (2020) identificou oscilações nas defasagens múltiplas de 12 meses em séries de temperatura, com comportamento senoidal.

A identificação do melhor modelo foi conduzida utilizando a função `auto.arima`. Os seguintes modelos foram selecionados como os melhores: modelo M1 - SARIMA com dados de vazão: $(1,0,1) (1,1,1)_{12}$; modelo M2 - SARIMAX com dados de vazão e precipitação como variável exógena: $(0,1,3) (2,0,0)_{12}$; modelo M3 - SARIMAX com dados de vazão e variáveis exógenas a precipitação e a temperatura: $(0,1,3) (2,0,0)_{12}$; e o modelo M4 - SARIMAX com dados de vazão e temperatura como variável exógena: $(2,0,1) (1,1,1)_{12}$.

A Tabela 5 compara os quatro modelos SARIMA quanto aos coeficientes, variância dos resíduos, AIC e BIC. O modelo M1 apresentou o pior desempenho, com maior variância residual e critérios AIC e BIC mais altos. O modelo M2 apresentou menor variância residual dentre os modelos, porém com valores de AIC e BIC superiores ao M3 que teve o melhor desempenho. Tal modelo incluiu precipitação e temperatura como variáveis exógenas. Já o modelo M4 teve desempenho intermediário, inferior aos modelos M2 e M3.

Tabela 5 - Coeficientes e métricas de desempenho dos modelos selecionados.


Modelo	SARIMA	Coeficientes	σ^2	AIC	BIC
M1	(1,0,1)(1,1,1) ₁₂	$\Phi_1 = 0.7038$ $\Theta_1 = -0.3991$ $\Phi_1 = -0.0803$ $\theta_1^{(S)} = -0.8601$	262	3453,79	3473,85
M2	(0,1,3)(2,0,0) ₁₂	$\Theta_1 = -0.6088$ $\Theta_2 = -0.1555$ $\Theta_3 = -0.2007$ $\Phi_1 = 0.156$ $\Phi_2 = 0.3585$ $\beta = 0.1553$	177,2	3372,00	3400,27
M3	(0,1,3)(2,0,0) ₁₂	$\Theta_1 = -0.6091$ $\Theta_2 = -0.1552$ $\Theta_3 = -0.2004$ $\Phi_1 = 0.1558$ $\Phi_2 = 0.3590$ $\beta_p = 0.1555$ $\beta_t = 0.0411$	178,1	3367,31	3399,24
M4	(2,0,1)(1,1,1) ₁₂	$\Phi_1 = 1,2624$ $\Phi_2 = -0,2739$ $\Theta_1 = -0,9264$ $\Phi_2 = -0.0941$ $\theta_1^{(S)} = -0.8792$ $\beta = -2,8680$	247,4	3424,87	3452,65

Legenda: M1: SARIMA (somente a vazão média mensal); M2: SARIMAX (vazão média mensal e precipitação média mensal); M3: SARIMAX (vazão média mensal, precipitação média mensal e temperatura média mensal); M4: SARIMAX (vazão média mensal e temperatura média mensal). Período considerado: janeiro de 1984 a dezembro de 2018. **Fonte:** Elaborado pelos autores (2025).

A Figura 6 apresenta a análise dos resíduos do modelo M3, o melhor modelo obtido. Os resíduos padronizados e a ACF indicam ausência de autocorrelação. O teste de Ljung-Box, cuja hipótese nula assume independência dos resíduos, apresentou p-valores superiores a 0,05, não

indicando evidências contra essa hipótese. Assim, os resíduos podem ser considerados ruído branco, o que confirma a adequação do modelo.

Figura 6 - Análise dos resíduos padronizados do modelo M3.



Fonte: Elaborado pelos autores (2025).

Os resultados obtidos são semelhantes aos de Meis, Llano & Rodríguez (2023), que também usaram modelos SARIMA para prever vazões mensais na bacia do Rio Paraná, incorporando o índice NIÑO 3.4 como variável exógena para melhorar a previsão de eventos extremos, como inundações.


Assim como neste estudo, Meis et al. (2023) utilizaram o teste de Ljung-Box para confirmar a adequação dos modelos, mesmo com algumas distorções nos resíduos. Os referidos autores também concluíram que a inclusão de variáveis exógenas, como o índice ENSO, melhorou a previsão de vazões em eventos extremos, reforçando a importância da análise de resíduos e outliers na avaliação da qualidade do modelo.

A Figura 7 apresenta as previsões dos modelos M1 a M4 de 3 a 12 meses. Observa-se maior variação entre os modelos no período chuvoso (janeiro a março), devido à instabilidade climática e à alta sensibilidade das vazões aos dados de entrada. No período seco (abril a setembro), as previsões foram mais próximas dos dados observados, destacando-se os modelos M2 e M3. Na previsão de 12 meses, todos os modelos apresentaram tendência de superestimação, mais acentuada no modelo M1 (37%) e menor no M2 e M3 (ambos com 20%). Durante a seca, as superestimações foram reduzidas, com destaque para o M4 (5%). De modo geral, todos captaram bem os extremos, com variações na precisão.

Assim, os resultados deste estudo mostraram que, durante os meses de vazões máximas, o modelo 1 (SARIMA) apresentou a maior superestimação, evidenciando menor precisão na captura dos picos de vazão. Em contraste, os modelos 2 e 3, com uma superestimação média de

20% na cheia e apenas 9% na seca, demonstraram uma melhor adaptação às máximas e mínimas médias observadas, aproximando-se do desempenho do modelo SARIMAX observado por Costa et al. (2023). Isso reforça a importância de modelos mais robustos, como o SARIMAX, especialmente quando integrados a variáveis exógenas relevantes, como precipitação e temperatura, para fornecer previsões de vazão mais precisas, principalmente em cenários de variações extremas, como picos e vales da série temporal.

Figura 7 - Previsão dos modelos 1 a 4 para os períodos de 3 meses (a), 6 meses (b), 9 meses (c) e 12 meses (d).



Legenda: Q: Vazão; M1: SARIMA (somente a vazão média mensal); M2: Sarimax (vazão média mensal e precipitação média mensal); M3: SARIMAX (vazão média mensal, precipitação média mensal e temperatura média mensal); M4: SARIMAX (vazão média mensal e temperatura média mensal). **Fonte:** Elaborado pelos autores (2025).

Cabe destacar que o modelo SARIMAX apresentou desempenho ligeiramente superior no conjunto de teste, o que se deve, em parte, à menor variabilidade hidrológica observada em 2019. Essa condição favoreceu a acurácia do modelo, que foi treinado para capturar padrões sazonais e tendências ao longo da série histórica. Tal comportamento é reconhecido em

aplicações hidrológicas, especialmente quando os dados de teste representam condições estáveis.

Quanto às métricas de desempenho (Tabela 5), os modelos M2 e M3 apresentaram o melhor desempenho geral entre os modelos avaliados, especialmente nos horizontes de médio e longo prazo (6, 9 e 12 meses), com baixos valores de erro (RMSE e MSE) e excelentes índices de NSE, KGE, e PBIAS, conforme classificação apresentada na Tabela 3. No entanto, para o horizonte de 3 meses, todos os modelos demonstraram desempenho insatisfatório, com destaque negativo para o índice NSE, indicando dificuldade na representação das variações observadas em curto prazo.

Tabela 5 - Métricas de desempenho dos modelos em relação aos cenários analisados.

Cenários	Treino					Teste				
	RMSE	MSE	NSE	KGE	PBIAS	RMSE	MSE	NSE	KGE	PBIAS
Previsão para 3 meses										
M1	15,88	252,06	0,67	0,75	-2,20	17,43	303,67	-58,91	0,17	26,50
M2	13,20	174,26	0,77	0,79	-0,30	4,07	16,54	-2,26	0,56	5,50
M3	13,22	174,66	0,77	0,78	-0,30	4,05	16,37	-2,23	0,56	5,50
M4	15,38	236,73	0,69	0,75	-0,70	15,68	245,96	-47,52	0,76	24,10
Previsão para 6 meses										
M1	15,88	252,06	0,67	0,75	-2,20	13,00	168,87	0,32	0,78	18,60
M2	13,20	174,26	0,77	0,79	-0,30	3,87	15,00	0,93	0,82	3,70
M3	13,22	174,66	0,77	0,78	-0,30	3,87	14,96	0,94	0,82	3,60
M4	15,38	236,73	0,69	0,75	-0,70	11,34	128,63	0,48	0,78	14,60
Previsão para 9 meses										
M1	15,88	252,06	0,67	0,75	-2,20	11,29	127,50	0,68	0,77	19,60
M2	13,20	174,26	0,77	0,79	-0,30	4,41	19,49	0,95	0,93	6,00
M3	13,22	174,66	0,77	0,78	-0,30	4,43	19,58	0,95	0,93	5,90
M4	15,38	236,73	0,69	0,75	-0,70	9,30	86,51	0,78	0,76	12,20
Previsão para 12 meses										
M1	15,88	252,06	0,67	0,75	-2,20	18,08	326,88	-0,02	0,59	29,00
M2	13,20	174,26	0,77	0,79	-0,30	8,83	78,05	0,75	0,85	13,10
M3	13,22	174,66	0,77	0,79	-0,30	8,81	78,67	0,76	0,85	13,00
M4	15,38	236,73	0,69	0,75	-0,70	15,43	237,98	0,25	0,61	21,3

Legenda: M1: SARIMA (somente a vazão média mensal); M2: Sarimax (vazão média mensal e precipitação mensal); M3: SARIMAX (vazão média mensal, precipitação mensal e temperatura média mensal); M4: SARIMAX (vazão média mensal e temperatura média mensal).

Fonte: Elaborado pelos autores (2025).

O modelo M2 apresentou o melhor desempenho para a fase de treino. Na fase de teste, o modelo M3 destacou-se por obter o melhor desempenho nas previsões com horizonte de 3, 6 e 12 meses, enquanto para a previsão de 9 meses seu desempenho foi bastante próximo ao do modelo M2.

O M4 apresentou bons resultados apenas no horizonte de 3 meses, com pior desempenho nos prazos mais longos. O modelo M1, baseado exclusivamente em dados de vazão, teve o pior desempenho geral, com exceção do horizonte de 9 meses.

De modo geral, inclusão da temperatura média mensal como variável exógena foi importante, gerando melhores resultados, quando incorporada juntamente às vazões, através do modelo M4, em comparação ao modelo SARIMA M1, que considerou apenas a vazão. Entretanto, ao comparar os modelos M2 e M3, a inclusão da temperatura como variável exógena foi indiferente já que as métricas de desempenho entre os modelos foram muito semelhantes.

Esses resultados reforçam a importância da inclusão de variáveis explicativas para melhorar a acurácia das previsões de vazão.


Tais resultados corroboram os encontrados por Hosseinzadeh et al. (2023), na previsão de vazões no rio Indus, afluente do Rio Colorado, localizado na região oeste dos Estados Unidos. No referido trabalho, foram utilizados modelos estocásticos, incluindo Random Forest Regression (RFR), Long Short-Term Memory (LSTM), SARIMA e o modelo Prophet. Os autores observaram uma melhora significativa nos parâmetros, especialmente no RMSE e no R^2 . Esses resultados indicam que a inclusão de variáveis climáticas, como a precipitação e a temperatura no modelo SARIMAX contribuiu para um desempenho melhor e preciso na previsão de vazão, especialmente em áreas impactadas pelas mudanças climáticas.

Por parcimônia e diante do desempenho semelhante observado entre os modelos M2 e M3, o modelo M2 foi considerado o mais adequado, uma vez que requer um conjunto menor de variáveis explanatórias. A previsão gerada pelo modelo M2 para os dados de treinamento está apresentada na Figura 8. No referido gráfico, observa-se a previsão dos valores para o período de teste (janeiro a dezembro de 2019), evidenciando a capacidade do modelo em captar os padrões sazonais e as flutuações relevantes presentes na série temporal.

A inclusão da temperatura como variável regressora no modelo SARIMAX ainda é pouco explorada na literatura científica, evidenciando uma lacuna relevante que merece atenção. Embora a temperatura influencie diretamente diversos processos hidrológicos e na dinâmica dos corpos hídricos por meio da evaporação, muitos estudos focam

predominantemente em variáveis como precipitação e vazão. Assim, preencher essa lacuna com investigações mais aprofundadas, contribui para o desenvolvimento de modelos preditivos melhor e representativos das condições ambientais locais, especialmente em áreas sensíveis a mudanças climáticas.

Figura 8 - Previsão do modelo M2: SARIMAX (0,1,3) (2,0,0)₁₂



Legenda: Observados = dados de vazões médias mensais observadas em m³/s; Vazões previstas: vazões médias mensais previstas pelo modelo 2 (variável explanatória: precipitação média mensal). **Fonte:** Elaborado pelos autores (2025).

4. Considerações finais

- Neste trabalho, foram analisados quatro modelos estocásticos distintos para a previsão de vazões médias mensais, contemplando não somente modelos da família SARIMA como também modelos SARIMAX ao contemplar a inclusão da precipitação e da temperatura como variáveis explanatórias.
- A consideração dos modelos SARIMAX, com precipitação e temperatura como variáveis explanatórias, melhorou a previsão de vazões mensais no Rio Itiquira, contribuindo para modelos mais adequados às condições locais e ao Pantanal Mato-grossense. Essa abordagem reforça as metodologias preditivas frente às incertezas

climáticas e pode ser aplicada em áreas como agricultura, energia, abastecimento, transporte e gestão hídrica, apoiando uma gestão mais eficiente e sustentável.

- Para trabalhos futuros, sugere-se a aplicação e a validação dos modelos em outras bacias hidrográficas, ampliando o campo de atuação e a generalização dos modelos estocásticos. Essa abordagem permite verificar a eficácia dos modelos ao lidar com diferentes condições hidrológicas e características regionais. Além disso, considerando a importância de captar corretamente os pontos extremos da série, recomenda-se o desenvolvimento de novas metodologias que integrem dados de vazão mínima e máxima.

Referências

- Agência Nacional de Águas. (2024). *Hidroweb: Sistemas de informações hidrológicas*. <http://hidroweb.ana.gov.br>
- Agência Nacional de Águas e Saneamento Básico. (2018). *Plano de recursos hídricos da Região Hidrográfica do Paraguai – PRH Paraguai: Resumo executivo*. Brasília: ANA.
- Aguado, E. A. (1982). Time series analysis of the Nile River low flows. *Annals of the Association of American Geographers*, 72(1), 109–119. <https://doi.org/10.1111/j.1467-8306.1982.tb01387.x>
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>
- Almeida, E. M., de Oliveira, A. C. S., Sanches, L., & Pascoa, M. A. R. (2020). Comportamento e previsão do nível do rio Cuiabá por meio de modelos SETAR. *Sigmae*, 9(2), 1–13.
- Barbosa, M. H., Carvalho, M. M., Sáfiadi, T., & Oliveira, L. F. C (2024). Modelagem Estocástica de Séries Temporais Pluviométricas e Fluviométrica da Bacia Hidrográfica do Rio Preto, Sudeste do Brasil. *Revista Brasileira de Meteorologia*, v. 39.
- Barbetta, P. (2006). Estatística aplicada às ciências sociais. Florianópolis: Editora UFSC.
- Bayer, D. M., Castro, N., & Bayer, F. M. (2012). Modelagem e Previsão de Vazões Médias Mensais do Rio Potiribu Utilizando Modelos de Séries Temporais. *RBRH*, v. 17, p. 229–239.
- Bayer, F. M., & Souza, A. M. (2010). Forecasting with Wavelets and Traditional Models: A Comparative. *Ver. Bras. Biom*, 28, 40-61.

- Bleidorn, M.T., Pinto, W.P., Braum, E.S., Lima, G. B., & Montebeller, C. A. (2019). Modelagem e previsão de vazões médias mensais do rio Jucu, ES, utilizando o modelo SARIMA. *IRRIGA*, v.24, n.2, p.320-335.
- Box, G.E.P., & Pierce, D.A. (1970). Distribution of Residual Autocorrelations in Autoregressive Integrated Moving Average Time Series Models. *Journal of the American Statistical Association*, 65, 1509-1526. <https://doi.org/10.1080/01621459.1970.10481180>
- Brunner, M. I., Slater, L., Tallaksen, L. M., & Clark, M. (2021). Challenges in modeling and predicting floods and droughts: A review. *WIREs Water*, v. 8, n. 3, p. e1520. <https://doi.org/10.1002/wat2.1520>
- Caixeta, L. T., Menezes Filho, F. C. M., & Fonseca, V. L. A. (2021). Modelagem e previsão de vazões médias mensais do Rio Paranaíba utilizando o modelo SARIMA. *Revista Ibero Americana de Ciências Ambientais*, v.12, n.3, p.255-267. <https://doi.org/10.6008/CBPC2179-6858.2021.003.0022>
- Caminha, A. R., Guimarães, L. R., Corrêa, F. V., Souza, G. R. De, Oliveira, L. F. C. D., & Sáfadi, T. (2025). Previsão de precipitação e vazão a partir da modelagem de séries temporais. *Revista Brasileira de Climatologia*, 36(21), 264–290. <https://doi.org/10.55761/abclima.v36i21.18885>
- Collischonn, W., & Dorneles, F. (2013). Hidrologia para Engenharia e Ciências Ambientais. Porto Alegre: *ABRH*. 350 p.
- Correa, G.O., Silva, F. E. O., & Matos, A. C. S. (2025). Hydrological signatures in Brazilian catchments: a machine learning approach for spatial estimates. *Journal des sciences hydrologiques [Hydrological sciences journal]*, p. 1–22. <https://doi.org/10.1080/02626667.2024.2446265>
- Costa, G. E. D. M. E., Menezes Filho, F. C. M. D., Canales, F. A., Fava, M. C.; Brandão, A. R. A., & De Paes, R. P. (2023). Assessment of Time Series Models for Mean Discharge Modeling and Forecasting in a Sub-Basin of the Paranaíba River, Brazil. *Hydrology*, v. 10, n. 11, p. 208. <https://doi.org/10.3390/hydrology10110208>
- Coy, M., Barrozo, J.C., & Souza, E.A (org). (2020). Estratégias de expansão do agronegócio em Mato Grosso: Os eixos da BR-163 e da BR-158 em perspectiva comparativa. Brasília: Editora *IABS*. 304 p.
- Dante, M., Shinma Galbetti, T. A., Galbetti, M. V., De Oliveira Ribeiro, V., & Oliveira Diodato, J. (2022). Comparação dos métodos da média aritmética, dos polígonos de thiessen e do

- IPD na avaliação espacial de dados pluviométricos. *Revista EIA*, 19(37), Reia37002. pp. 1-11.
- Dawson, C. W., Abrahart, R. J., & See, L. M. (2007). HydroTest: A web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts. *Environmental Modelling & Software*, v. 22, n. 7, p. 1034–1052. <https://doi.org/10.1016/j.envsoft.2006.06.008>
- Duarte, V. B. R., Silva, F. de C. S. da., Souza, I. V., Silva, M. V. C., Sousa, H. G. de A., Giongo, M., & Viola, M. R. (2019). Previsão de vazão na bacia hidrográfica do rio Manuel Alves da Natividade utilizando o modelo de séries temporais SARIMA. *Journal of Biotechnology and Biodiversity*, 7(4), 457–468. <https://doi.org/10.20873/jbb.uft.cemaf.v7n4.duarte>
- Ferreira, P. M. D. L., Paz, A. R. D., & Bravo, J. M. (2020). Objective functions used as performance metrics for hydrological models: state-of-the-art and critical analysis. *RBRH*, v. 25, p. e42. <https://doi.org/10.1590/2318-0331.252020190155>
- Figueiredo, N.M., & Blanco, C.J.C. (2014). Simulação de vazão e níveis de água médio mensais para o rio Tapajó usando modelos ARIMA. *Revista Brasileira de Recursos Hídricos*, v.19, n.3, p.111–126.
- Gharbia, S., Riaz, K., Anton, I., Makrai, G., Gill, L., Creedon, L., McAfee, M., Johnston, P., & Pilla, F. (2022). Hybrid Data-Driven Models for Hydrological Simulation and Projection on the Catchment Scale. *Sustainability*, 14(7), 4037. <https://doi.org/10.3390/su14074037>
- Gupta, H.V., Kling, H., Yilmaz, K.K., & Martinez, G.F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling, *Journal of Hydrology*, Volume 377, Issues 1–2. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Hamza, K., & Hassan, S. A. (2015). Stochastic river flow modelling Stochastic River of Upper Indus Basin. *Journal of Basic & Applied Sciences*, v. 11, p. 630-636.
- Hosseinzadeh, P., Nassar, A., Boubrahimi, S. F., & Hamdi, S. M. (2023). ML-Based Streamflow Prediction in the Upper Colorado River Basin Using Climate Variables Time Series Data. *Hydrology*, 10(2), 29. <https://doi.org/10.3390/hydrology10020029>
- Hyndman, R. J., & Khandakar, Y. (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3), 1–22. <https://doi.org/10.18637/jss.v027.i03>

- Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*, 2nd edition, *OTexts*: Melbourne, Australia.
- Hyndman, R.J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*, 3rd ed., *OTexts*: Melbourne, VIC, Australia.
- Hyndman, R.J., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., & Yasmien F (2024). *Forecast: Forecasting functions for time series and linear models*. R package version 8.23.0. <https://pkg.robjhyndman.com/forecast/>
- Jimeno-Sáez, P., Senent-Aparicio, J.; Pérez-Sánchez, J.; & Pulido-Velazquez, D. (2018). A Comparison of SWAT and ANN Models for Daily Runoff Simulation in Different Climatic Zones of Peninsular Spain. *Water*, v. 10, n. 2, p. 192. <https://doi.org/10.3390/w10020192>
- Kim, D., Park, Han, H., Lee, H., Kim, H.S., & Kim, S. (2023). Application of AI-based models for flood water level forecasting and flood risk classification. *KSCE Journal of civil engineering*, v. 27, n. 7, p. 3163–3174.
- Klotz, D., Kratzert, F., Gauch, M., Sampson, A.K., Brandstetter, J., Klambauer, G., Hochreiter, S., & Nearing, G. (2022). Uncertainty estimation with deep learning for rainfall–runoff modeling. *Hydrology and earth system sciences*, v. 26, n. 6, p. 1673–1693. DOI: <https://doi.org/10.5194/hess-26-1673-2022>
- Lana, J. C. (2023). Gully erosion prediction method from geoenvironmental data and supervise machine learning techniques. *MethodsX*, 10.
- Katipoğlu, O.M., Keblouti, M., & Mohammadi, B. (2023). Application of novel artificial bee colony optimized ANN and data preprocessing techniques for monthly streamflow estimation. *Environ Sci Pollut Res* 30, 89705–89725. <https://doi.org/10.1007/s11356-023-28678-4>
- Kotteck, M., Grieser, J., Beck, C., Rudolf, B., & Rubel, F. (2006). World Map of the Köppen-Geiger climate classification updated. *Meteorologische Zeitschrift*, v. 15, n. 3, p. 259–263, <https://doi.org/10.1127/0941-2948/2006/0130>
- Lee, J., & Cho, Y. (2022). National-Scale Electricity Peak Load Forecasting: Traditional, Machine Learning, or Hybrid Model?. *Energy*, 239, 122366.
- Legates, D. R., & McCabe Junior, G. J. (1999). Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1), 233–241. <http://dx.doi.org/10.1029/1998WR900018>

- Mao, G., Wang, M., Liu, J., Wang, Z., Wang, K., Meng, Y., Zhong, R., Wang, H., & Li, Y. (2021). Comprehensive comparison of artificial neural networks and long short-term memory networks for rainfall-runoff simulation. *Physics and Chemistry of the Earth, Parts A/B/C*, v. 123, p. 103026. <https://doi.org/10.1016/j.pce.2021.103026>
- Meis, M., Llano, M.P., & Rodriguez, D. (2023). A statistical tool for a hydrometeorological forecast in the lower La Plata Basin, *International Journal of River Basin Management*, 21:4, 685-696. <http://doi.org/10.1080/15715124.2022.2079657>
- Menezes Filho, F. C. M. (2020). Modelagem e previsão de temperaturas médias mensais de Rio Paranaíba/MG utilizando modelos de séries temporais. *Revista Ibero Americana de Ciências Ambientais*, v.11, n.6, p.251-261. <http://doi.org/10.6008/CBPC2179-6858.2020.006.0021>
- Morettin, P. A., & Toloi, C.M.C. (2018). *Análise de Series Temporais*, Volume 1, Terceira edição, *Blucher*.
- Muñoz Sabater, J. (2019). ERA5-Land monthly averaged data from 1981 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). <http://doi.org/10.24381/cds.68d2bb30>
- Naganna, S. R., Marulasiddappa, S. B., Balreddy, M. S., & Yaseen, Z. M. (2023). Daily scale streamflow forecasting in multiple stream orders of Cauvery River, India: Application of advanced ensemble and deep learning models. *Journal of Hydrology*, v. 626, p. 130320. <https://doi.org/10.1016/j.jhydrol.2023.130320>
- Naghetini, M., & Pinto, E. J. A. (2007). *Hidrologia Estatística*. Belo Horizonte: CPRM. 552 p.
- Nearing, G., Cohen, D., Dube, V., Gauch, M., Gilon, O., Harrigan, S., ... & Matias, Y. (2024). Global prediction of extreme floods in ungauged watersheds. *Nature*, 627(8015), 559–563. <https://doi.org/10.1038/s41586-024-07145-1>
- Nguyen, T., Vu, D., Mai, S. T., & Dang, T. D. (2023). Streamflow Prediction in the Mekong River Basin Using Deep Neural Networks. *IEEE Access*, v. 11, p. 97930–97943. <https://doi.org/10.1109/ACCESS.2023.3301153>
- Pant, J., Sharma, R.K., Juyal, A., Singh, D., Pant, H., & Pant, P. (2022). A Machine-Learning Approach to Time Series Forecasting of Temperature. In *Proceedings of the 6th International Conference on Electronics, Communication and Aerospace Technology*, Coimbatore, India; pp. 1125–1129.

- Patterson, N. K., Lane, B.A, Sandoval-Solis, S., Persad, G.G., & Ortiz-Partida, J. P. (2022). Projected effects of temperature and precipitation variability change on streamflow patterns using a functional flows approach. *Earth's future*, v. 10, n. 7. <https://doi.org/10.1029/2021EF002631>
- Peixoto, F. D. S., Soares, J. A., & Ribeiro, V. S. (2021). Conflitos pela água no Brasil. *Sociedade & Natureza*, v. 34, n. 1. <https://doi.org/10.14393/SN-v34-2022-59410>
- Pfaff, B. (2008). Analysis of Integrated and Cointegrated Time Series with R, Second edition. Springer, New York. ISBN 0-387-27960-. <https://www.pfaffikus.de>
- Pinto, W. P., Lima, G. B., & Zanetti, J.B. (2015). Análise comparativa de modelos de séries temporais para modelagem e previsão de regimes de vazões médias mensais do Rio Doce, Colatina – Espírito Santo. *Ciência e Natura*, v. 37 n. 4, p. 1-11.
- Projeto Mapbiomas. (2022). Coleção Beta de Mapas Anuais de Cobertura e Uso da Terra do Brasil com 10 metros de resolução espacial. https://storage.googleapis.com/mapbiomas-public/initiatives/brasil/collection_7.1/lcl/coverage/brasil_coverage_2022.tif
- Qin, L., Tian, Z., Lin, L., Yi, C., & Chen, J. (2024). Evaluation and development of pedotransfer functions of saturated hydraulic conductivity for subtropical soils. *Geoderma*, 448, p. 1-10.
- R Core Team. (2024). R: A Language and Environment for Statistical Computing. *R Foundation for Statistical Computing*, Vienna, Austria.
- Rao, S. G., & Quillan, E. W. (1982). Stochastic Arima Models for Monthly Streamflows. *Developments in Water Science*, 474–486. [https://doi.org/10.1016/s0167-5648\(08\)70732-9](https://doi.org/10.1016/s0167-5648(08)70732-9)
- Romanowicz, R. J., Osuch, M., & Grabowiecka, M. (2013). On the choice of calibration periods and objective functions: a practical guide to model parameter identification. *Acta Geophysica*, 61(6), 1477-1503. <http://dx.doi.org/10.2478/s11600-013-0157-6>
- Safeeq, M, Grant, G. E., Lewis, S. L., Kramer, M. G., & Staab, B. (2014). A hydrogeologic framework for characterizing summer streamflow sensitivity to climate warming in the Pacific Northwest, USA. *Hydrology and earth system sciences*, v. 18, n. 9, p. 3693–3710.
- Said, S. E., & Dickey, D. A. (1984). Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order. *Biometrika*, v.71, p.599-607.
- Sax, C., & Eddelbuettel, D. (1982). Seasonal Adjustment by X-13ARIMA-SEATS in R. *Journal of Statistical Software*, 87(11), 1–17. <http://dx.doi.org/10.18637/jss.v087.i11>

- Schwarz, G. (1978). Estimating the Dimension of a Model. *Ann. Statist.* 6 (2) 461 – 464. <https://doi.org/10.1214/aos/1176344136>
- Serviço Geológico Do Brasil [CPRM] (2024). Boletim de Monitoramento da Bacia do Rio Paraguai: Seca de 2024 (Boletim nº 17, 30 de Outubro de 2024). *Serviço Geológico do Brasil*. https://www.sgb.gov.br/sace/boletins/Paraguai/20241030_17-20241030_%20-%20173325.pdf
- Shah, H. S. M., Yassin, M. A., Abba, S. I., Lawal, D. U., Hussein Al-Qadami, E. H., Teo, F. Y., Mustaffa, Z., & Aljundi, I. H. (2023). Flood Risk and Vulnerability from a Changing Climate Perspective: An Overview Focusing on Flash Floods and Associated Hazards in Jeddah. *Water*, v. 15, n. 20, p. 3641. <https://doi.org/10.3390/w15203641>
- Siqueira, F. B. (2021). Conflitos de Usos Múltiplos dos Recursos Hídricos e Reservatórios Hidrelétricos no Brasil. Tese de doutorado, Universidade Federal do Rio de Janeiro, Programa de Planejamento Energético, *COPPE*, Rio de Janeiro.
- Todeschini, T., & Menezes Filho, F. C. M. (2024). Gap Filling and consistency analysis in monthly rainfall series: case study in southeastern Mato Grosso. *Revista Brasileira de Ciência, Tecnologia e Inovação*, v. 9, n. 2, p. 140–146.
- Trapletti, A., & Hornik, K. (2024). Tseries: Time Series Analysis and Computational Finance. *R package version 0.10-58*. <https://CRAN.R-project.org/package=tseries>
- Tucci, C.E.M. (org.). (2015). Hidrologia: ciência e aplicação. Porto Alegre: *Editora da UFRGS/ABRH*. 943 p.
- Yonus, M., & Hassan, S.A. (2022). The Impact of Climate Change on Stochastic Variations of the Hydrology of the Flow of the Indus River. *Slovak Journal of Civil Engineering*. Slovak University of Technology;30}(1): 33-41. <https://doi.org/10.2478/sjce-2022-0004>
- Wohling, T., Samaniego, L., & Kumar, R. (2013). Evaluating multiple performance criteria to calibrate the distributed hydrological model of the upper Neckar catchment. *Environmental Earth Sciences*, 69(2), 453-468. <http://dx.doi.org/10.1007/s12665-013-2306-2>
- Zambrano-Bigiarini, M. (2024). hydroGOF: Goodness-of-fit functions for comparison of simulated and observed hydrological time series. doi:10.5281/zenodo.839854, *R package version 0.6-0.1*. <https://cran.r-project.org/package=hydroGOF>.

Publisher: Universidade Federal de Jataí. Instituto de Geografia. Programa de Pós-graduação em Geografia. Publicação no Portal de Periódicos UFJ. As ideias expressadas neste artigo são de responsabilidade de seus autores, não representando, necessariamente, a opinião dos editores ou da universidade.

Contribuições dos autores: Thaiana Todeschini: coleta e análise dos dados, organização dos dados e tabelas, escrita e discussão; Frederico Carlos Martins de Menezes Filho: supervisão, análise formal de dados, validação e revisão da escrita e discussão. Declaramos ainda ciência das Diretrizes Gerais da Geoambiente On-line.

Conflito de interesse: Os autores declaram que não possuem interesses financeiros ou não financeiros relevantes relacionados a este trabalho.