





PREVISÃO DE PRECIPITAÇÃO E VAZÃO A PARTIR DA MODELAGEM DE SÉRIES TEMPORAIS

*Precipitation and streamflow forecasting based on time series
modeling*


*Previsión de precipitaciones y caudales basada en la
modelización de series temporales*

Alice Raquel Caminha  

Programa de Pós-Graduação em Recursos Hídricos, Universidade Federal de Lavras (UFLA)
alicercazinha@gmail.com

Lucas Ribeiro Guimarães  


Programa de Pós-Graduação em Recursos Hídricos, Universidade Federal de Lavras (UFLA)
lucas.guimaraes6@estudante.ufla.br

Flávia Vilela Corrêa  

Programa de Pós-Graduação em Recursos Hídricos, Universidade Federal de Lavras (UFLA)
flavia.correa1@estudante.ufla.br

Gabriela Rezende de Souza  

Departamento de Engenharia Civil, Universidade Federal de Viçosa (UFV)
gabriela.rezende.souza@ufv.br

Luiz Fernando Coutinho de Oliveira  

Programa de Pós-Graduação em Recursos Hídricos, Universidade Federal de Lavras (UFLA)
coutinho@ufla.br

Thelma Sáfyadi  

Departamento de Estatística, Instituto de Ciências Exatas, Universidade Federal de Lavras (UFLA)
safadi@ufla.br

Resumo: A modelagem de séries temporais é uma ferramenta importante para previsão do comportamento de variáveis hidrológicas e, assim, pode ser aplicada ao planejamento urbano para a antecipação e minimização de impactos negativos causados por desastres naturais. Dessa forma, o objetivo deste trabalho foi analisar, modelar e realizar previsões com base nas séries temporais de vazões e precipitações mensais de estações localizadas na microrregião de Caratinga, pertencente à bacia hidrográfica do Rio Doce. As etapas da modelagem consistiram na obtenção dos dados, identificação de possíveis modelos, estimativa dos parâmetros, diagnóstico e, por fim, realização das previsões. Foram selecionados os modelos que apresentaram o menor valor para, pelo menos, dois dos critérios de seleção adotados, sendo eles o de Akaike, Hannan Quinn e Schwarz. Quanto ao ajuste, embora os modelos tenham apresentado dificuldades em captar os picos das séries, o SARIMA(1,1,2)(0,1,1)₁₂ mostrou boa aderência às vazões mínimas observadas e foi eficaz na representação dos períodos históricos de estiagem. Por meio da análise residual, todos os modelos foram considerados adequados para a realização de previsões. Para o ano de 2020, a maioria dos modelos apresentou desempenho satisfatório. O SARIMA(0,0,0)(0,1,1)₁₂ e o SARIMA(1,1,2)(0,1,1)₁₂ foram os mais adequados para prever precipitações e vazões, respectivamente. Apesar das limitações, os resultados demonstram a relevância da modelagem como suporte à gestão dos recursos hídricos na região, fornecendo subsídios para o conhecimento da disponibilidade hídrica nos períodos de seca.

Palavras-chave: Modelos SARIMA. Sazonalidade. Modelos hidrológicos. Recursos Hídricos.

Abstract: Time series modeling is an essential tool for forecasting the behavior of hydrological variables and can therefore be applied to urban planning to anticipate and mitigate the negative impacts of natural disasters. This study aimed to analyze, model, and generate forecasts based on the time series of monthly streamflow and precipitation data from stations located in the microregion of Caratinga, part of the Rio Doce watershed. The modeling steps included data acquisition, identification of potential models, parameter estimation, diagnostics, and, finally, forecasting. Models were selected based on achieving the lowest values in at least two of the selection criteria adopted: Akaike, Hannan-Quinn, and Schwarz. Regarding model fit, although challenges were encountered in capturing peak values in the series, the SARIMA(1,1,2)(0,1,1)₁₂ model demonstrated good adherence to observed minimum streamflows and effectively represented historical drought periods. Residual analysis indicated that all models were suitable for forecasting purposes. For the year 2020, most models showed satisfactory performance. The SARIMA(0,0,0)(0,1,1)₁₂ and SARIMA(1,1,2)(0,1,1)₁₂ models were the most appropriate for forecasting precipitation and streamflow, respectively. Despite limitations, the results underscore the relevance of modeling as a support tool for water resource management in the region, providing insights into water availability during drought periods.

Keywords: SARIMA Models. Seasonality. Hydrological Models. Water Resources.

Resumen: La modelización de series temporales es una herramienta esencial para predecir el comportamiento de las variables hidrológicas y, por lo tanto, puede aplicarse a la planificación urbana para anticipar y mitigar los impactos negativos de los desastres naturales. Este estudio tuvo como objetivo analizar, modelar y realizar previsiones basadas en las series temporales de caudales y precipitaciones mensuales de estaciones ubicadas en la microrregión de Caratinga, perteneciente a la cuenca hidrográfica del río Doce. Las etapas de la modelización incluyeron la obtención de datos, la identificación de posibles modelos, la estimación de parámetros, el diagnóstico y, finalmente, la realización de las previsiones. Los modelos fueron seleccionados en función de alcanzar los valores más bajos en al menos dos de los criterios de selección adoptados: Akaike, Hannan-Quinn y Schwarz. En cuanto al ajuste, aunque se presentaron dificultades para capturar los picos de las series, el modelo SARIMA(1,1,2)(0,1,1)₁₂ mostró una buena adherencia a los caudales mínimos observados y fue eficaz en la representación de los períodos históricos de sequía. El análisis de los residuos indicó que todos los modelos eran adecuados para realizar previsiones. Para el año 2020, la mayoría de los modelos

mostró un desempeño satisfactorio. Los modelos $SARIMA(0,0,0)(0,1,1)_{12}$ y $SARIMA(1,1,2)(0,1,1)_{12}$ fueron los más apropiados para predecir precipitaciones y caudales, respectivamente. A pesar de las limitaciones, los resultados destacan la relevancia de la modelización como herramienta de apoyo para la gestión de recursos hídricos en la región, proporcionando información sobre la disponibilidad hídrica durante períodos de sequía.

Palabras-clave: Modelos SARIMA. Estacionalidad. Modelos hidrológicos. Recursos hídricos.

Submetido em: 21/08/2024

Aceito para publicação em: 03/02/2025

Publicado em: 04/02/2025

1. INTRODUÇÃO

O estudo de variáveis hidrológicas, como precipitação e vazão, tem se tornado um campo essencial para o planejamento urbano e a gestão adequada dos recursos hídricos, especialmente em um contexto de crescente vulnerabilidade a desastres naturais. Prever o comportamento dessas variáveis contribui para garantir a disponibilidade de água, implementar estratégias para reduzir ou minimizar impactos, otimizar a operação de infraestruturas hídricas, como reservatórios e sistemas de drenagem; além de fornecer subsídios ao planejamento de atividades agrícolas e instalação de sistemas de alerta (Medeiros *et al.*, 2020).

Diversos métodos de previsão têm sido desenvolvidos para explicar o comportamento de variáveis hidrológicas, buscando identificar padrões climáticos regionais. A lógica *fuzzy* utiliza conceitos de incerteza e aproximação para modelar variáveis complexas e imprecisas em ambientes com alta variabilidade (Janarthanan *et al.*, 2021; Zahran *et al.*, 2023). Já as redes neurais artificiais imitam o funcionamento do cérebro humano, aplicando aprendizado supervisionado para identificar padrões e relações não lineares em grandes volumes de dados, minimizando erros de previsão com base nos dados de treinamento (Alberton *et al.*, 2021; Araújo *et al.*, 2022).

Os modelos de séries temporais, por sua vez, são amplamente utilizados para detectar tendências, remover periodicidades e capturar a sazonalidade dos dados, o que permite prever variações hidrológicas a partir de observações passadas (Masum *et al.*, 2022; Rawat *et al.*, 2022). Cada um desses métodos oferece contribuições distintas para análise e previsão, sendo escolhidos conforme a natureza dos dados e os objetivos específicos do estudo.

Entre os modelos de séries temporais, o Autorregressivo Integrado de Média Móvel (ARIMA) é amplamente utilizado para o estudo de variáveis hidrológicas (Al Balasmeh *et al.*, 2019; Bezerra *et al.*, 2023). A versão sazonal deste modelo, o SARIMA (*Seasonal Autoregressive Integrated Moving Average*), é particularmente eficaz para capturar, além das autocorrelações temporais, os padrões sazonais característicos de variáveis ambientais, tornando-se um instrumento eficaz para realização de previsões.

Estudos recentes destacam o uso do modelo SARIMA para prever a precipitação pluviométrica em diferentes regiões, comprovando a aplicabilidade do modelo na análise da

variabilidade temporal da precipitação. Santos *et al.* (2021) focaram na adaptação do SARIMA para a previsão de chuvas, ressaltando seu potencial em contribuir para o planejamento de recursos hídricos, enquanto Lima *et al.* (2020) aplicaram tanto a estatística descritiva quanto modelos SARIMA para estudar os padrões de precipitação no sudeste do Mato Grosso, evidenciando a relevância do modelo em contextos regionais.

Bleidorn *et al.* (2019) e Duarte *et al.* (2019), por sua vez, utilizaram modelos SARIMA para prever vazões médias mensais em bacias hidrográficas específicas, como as do rio Jucu, no Espírito Santo, e a do rio Manuel Alves da Natividade, no Tocantins. Ambos os trabalhos mostraram a capacidade dos modelos em produzir previsões consistentes, oferecendo informações valiosas acerca da disponibilidade hídrica em períodos críticos.

Diante desse cenário, este estudo propõe a análise, modelagem e previsão do comportamento de variáveis hidrológicas por meio de modelos SARIMA, utilizando dados mensais de precipitação e vazão para a microrregião de Caratinga, MG. Essa região é notoriamente vulnerável a catástrofes ambientais, refletindo a necessidade da criação e implementação de ferramentas preditivas eficazes para auxiliar a gestão dos recursos hídricos a longo prazo.

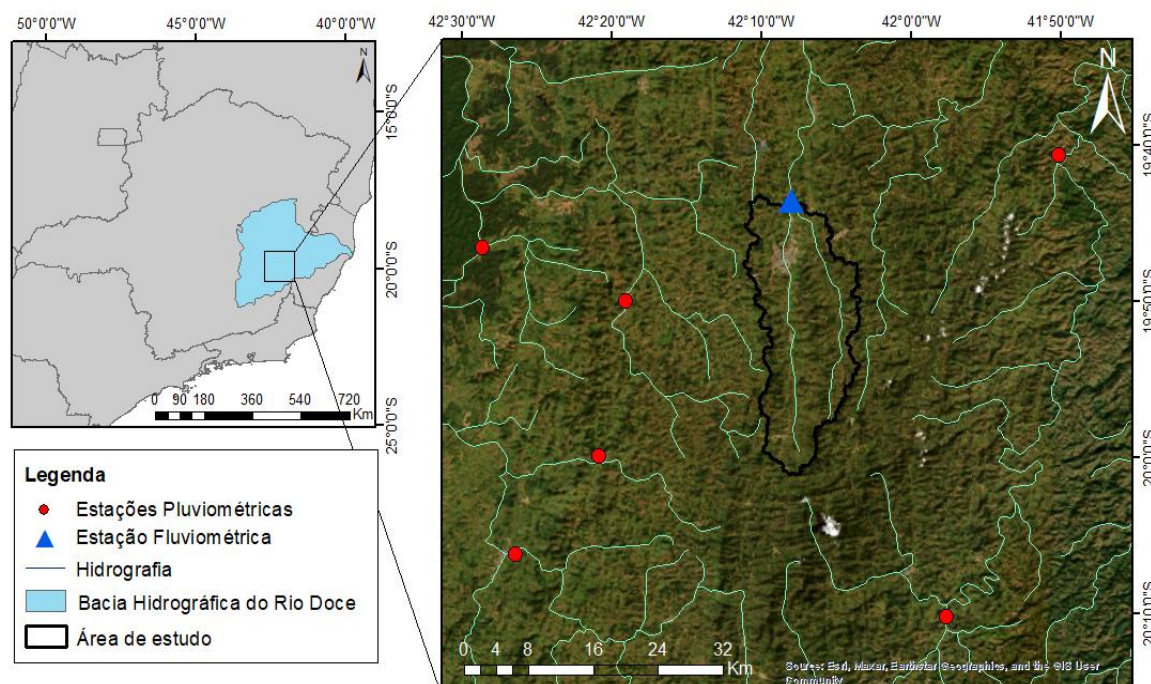
2. METODOLOGIA

2.1. Caracterização da área de estudo

O Rio Caratinga é um afluente da margem esquerda do Rio Doce, cuja área de drenagem abrange, total ou parcialmente, 29 municípios, sendo a segunda com maior densidade populacional entre as sub-bacias do Rio Doce. A região enfrenta desafios ambientais significativos, como degradação do solo, escassez hídrica e poluição, além de problemas relacionados à infraestrutura de drenagem urbana (IGAM, 2010).

Os municípios onde estão localizadas as estações pertencem às mesorregiões Zona da Mata, Vale do Rio Doce e, com maior relevância, à microrregião de Caratinga. A localização geográfica das estações está apresentada na Figura 1.

Figura 1 - Localização geográfica das estações analisadas.



Fonte: Elaborado pelos autores (2024).

A área de estudo possui altitudes entre 121 e 1576 m e uma declividade média de 30%, caracterizando um relevo forte ondulado (Santos *et al.*, 2018). Em termos de classificação dos solos, predomina o Argissolo Vermelho-Amarelo Eutrófico (51%), seguido pelo Latossolo Vermelho-Amarelo Distrófico (39%), e, em menores proporções, Latossolo Amarelo Distrófico (8%) e Neossolo Litólico Distrófico (2%) (IDE-SISEMA, 2024). As principais unidades geológicas incluem os complexos Juiz de Fora e Pocrane, além da Suíte Galiléia, Tonalito Vermelho Novo, e os grupos Rio Doce e Raposo (CPRM, 2020).

Segundo a classificação de Köppen-Geiger, o clima na região é do tipo Aw (clima tropical com estação seca no período de inverno) (Alvares *et al.*, 2013; Martins *et al.*, 2018). A temperatura média é de 22,5°C, enquanto as temperaturas máxima e mínima são, em média, de 28,4°C e 16,9°C, respectivamente (INMET, 2022). A precipitação média anual é de 1089 mm, sendo o mês de dezembro o mais chuvoso, com 252,7 mm em média. Por outro lado, o menor volume pluviométrico é atribuído ao mês de julho, com uma lâmina acumulada média de 6 mm (ANA, 2022).

2.2. Obtenção dos dados

O estudo foi desenvolvido a partir das séries históricas de seis estações pluviométricas e uma fluviométrica, extraídas da plataforma *Hidroweb*, contemplando o período de janeiro de 1990 a dezembro de 2020 (Tabela 1). O período de 1990 a 2019 foi utilizado para o ajuste dos modelos e o ano de 2020, para a avaliação do desempenho destes na realização de previsões. Para o preenchimento de falhas nas séries de precipitação, foi utilizado o método da ponderação regional, usualmente adotado por ser considerado mais simples para preencher falhas de séries pluviométricas mensais e anuais (Machado e Assis, 2018; Ruezzene *et al.*, 2021).

Tabela 1- Descrição das estações utilizadas.

Nome da estação	Tipo	Código	Coordenadas		Altitude (m)
			Latitude	Longitude	
Santo Antônio do Manhuaçu	Pluviométrica	1941011	-19,6783	-41,8361	290
Bom Jesus do Galho	Pluviométrica	1942002	-19,8336	-42,3178	505
Vermelho Velho	Pluviométrica	1942006	-19,9989	-42,3475	420
Cachoeira do Óculos - Montante	Pluviométrica	1942031	-19,7769	-42,4769	241
Fazenda Vargem Alegre	Pluviométrica	2041048	-20,1706	-41,9611	523
Raul Soares - Montante	Pluviométrica	2042008	-20,1036	-42,4400	305
Caratinga	Fluviométrica	56925100	-19,7267	-42,1331	565

Fonte: Elaborado pelos autores (2024).

2.3. Análise descritiva

A análise descritiva de cada série foi realizada calculando-se a média, mediana, valores mínimos, máximos, desvio padrão e coeficiente de variação. A caracterização visual do comportamento das variáveis se deu por meio da geração dos gráficos das séries temporais de cada estação. Posteriormente, o Método dos Mínimos Quadrados Ordinários foi utilizado

para confirmar e identificar a existência de tendências nas séries. Em caso afirmativo, foram aplicadas diferenciações sucessivas para tornar a série estacionária.

O período de janeiro de 1990 a dezembro de 2019 foi utilizado para etapa de modelagem e o ano de 2020, para avaliação e validação das previsões fornecidas pelos modelos. Todas as etapas envolvidas neste estudo foram realizadas no software estatístico Gretl (Cottrell e Lucchetti, 2022).

2.4. Identificação dos modelos e estimativa dos parâmetros

Foram ajustados diferentes modelos SARIMA para cada série. Estes modelos agregam os componentes autorregressivos, de médias móveis e sazonais e podem ser descritos como:

$$\phi_p(B) \Phi_P(B^s) (1-B)^d (1-B^s)^D Z_t = \theta_q(B) \Theta_Q(B^s) a_t \quad (1)$$

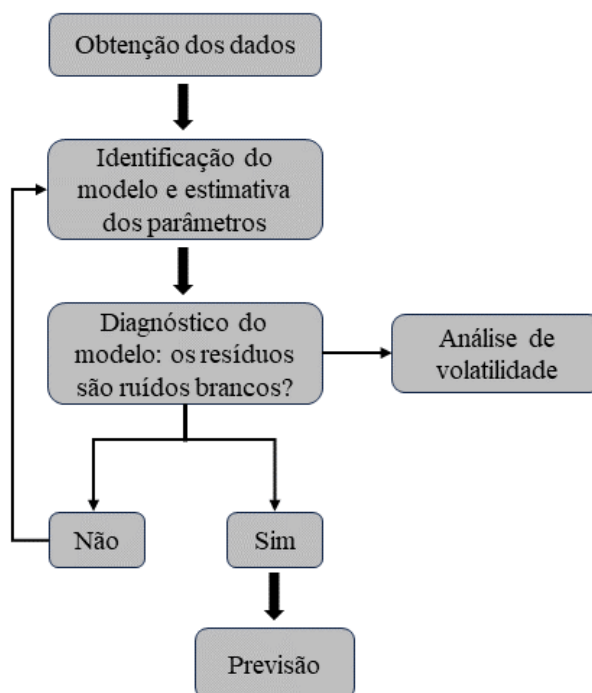
Sendo, ϕ_p e Φ_P , os parâmetros autorregressivos; θ_q e Θ_Q , os parâmetros de média móvel; B o operador de retardo; (p,q,d) , as ordens da parte não-sazonal; (P,D,Q) , as ordens da parte sazonal; s , o período sazonal da série e a_t , o ruído branco

Partindo do pressuposto de que o modelo possui base estocástica e pode ser caracterizado por seus dados passados, neste estudo foi adotada a metodologia proposta por Box e Jenkins (1976), que consiste na identificação do modelo, estimativa de seus parâmetros e aplicação do modelo ajustado para realização de previsões. As etapas deste método estão apresentadas na Figura 2. A identificação do modelo tem a finalidade de determinar as ordens das partes não-sazonal e sazonal. Inicialmente, essa investigação foi feita a partir da interpretação dos gráficos das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) das séries temporais, em busca de autocorrelação significativamente diferente de zero nas defasagens, indicando a existência de correlação serial a ser modelada.

Foram testados os modelos propostos de forma que as ordens autorregressivas (p e P) e de médias móveis (q e Q) fossem menores ou iguais a 3; e as diferenças (d e D) menores que 2, conforme procederam Bayer *et al.* (2012). Segundo os autores, dessa forma é possível conciliar as indicações das possíveis ordens, inicialmente fornecidas pelos correlogramas das

séries originais, e a busca por um modelo que forneça qualidade no ajuste de acordo com sua complexidade.

Figura 2 - Fluxograma das etapas da modelagem de séries temporais.



Fonte: Elaborado pelos autores (2024).

Para seleção do melhor modelo, foram adotados os critérios de Akaike (AIC) (Akaike, 1974); Hannan Quinn (HQ) (Hannan e Quinn, 1979) e Schwarz (SW) (Schwarz, 1978), sendo considerado o modelo mais adequado aquele que apresentasse os menores valores para, pelo menos, dois dos critérios adotados.

2.5. Diagnóstico dos modelos

Após a determinação dos modelos propostos para cada série e a estimação de seus parâmetros, foi realizado o diagnóstico, que envolveu a análise dos correlogramas residuais, etapa fundamental para avaliar se estes modelos conseguiram representar adequadamente os dados. Nesse sentido, os resíduos não devem ser autocorrelacionados, uma vez que a correlação entre eles indica a existência de informações que não foram incorporadas ao

modelo. Essa etapa foi feita buscando observar se todos os valores estão contidos dentro do intervalo de confiança de 95%, constituindo um ruído branco com p-valor > 0,05 para uma defasagem adotada de 36 *lags*.

2.6. Análise de volatilidade

Segundo Oliveira *et al.* (2015), uma parcela considerável das séries de fenômenos naturais possui heterocedasticidade, ou seja, a variância dos resíduos não é constante ao longo do intervalo de valores. A volatilidade de uma série temporal, por sua vez, refere-se à medida da variação ou dispersão dos valores dessa série ao longo do tempo. Em termos mais técnicos, é a intensidade das flutuações ou mudanças nos valores de uma série temporal, indicando o grau de incerteza ou risco associado a essas flutuações.

Dessa forma, após definido o melhor modelo SARIMA para os dados de vazão mensal e obtidos os respectivos resíduos com características de ruído branco, foi realizada a análise dos resíduos quadrados, os quais devem apresentar correlação serial caso haja volatilidade na série. Em caso afirmativo, aplicaram-se aos resíduos os modelos do tipo ARCH(*m*) - *Autoregressive Conditional Heteroskedasticity* (Engle, 1982), que são capazes de modelar a volatilidade da série e podem ser descritos como:

$$X_t = \sqrt{h_t} a_t \quad (2)$$

$$h_t = \alpha_0 + \alpha_1 X_{t-1}^2 + \dots + \alpha_m X_{t-m}^2 \quad (3)$$

Em que X_t é o resíduo não correlacionado; a_t é um ruído branco normalmente distribuído e com média zero; h_t é a variância condicional em função do tempo e α_0 , α_i e α_m são os parâmetros de ajuste do modelo, com $\alpha_0 > 0$; $\alpha_i \geq 0$; $i = 1 \dots m - 1$ e $\alpha_m > 0$.

2.7. Previsões

Concluída a etapa anterior, foram feitas as previsões das precipitações mensais e vazões mensais para um horizonte de 12 meses (janeiro a dezembro de 2020), período que não foi considerado para o ajuste do modelo. O desempenho dos modelos foi verificado por

meio dos coeficientes estatísticos Raiz do Erro Quadrático Médio (RMSE), coeficiente de correlação de Pearson (r) e coeficiente de Nash-Sutcliffe (CNS). Conforme classificação proposta por Moriasi *et al.* (2007), $CNS > 0,65$ indica um ajuste muito bom; $0,54 < CNS < 0,65$, bom; e $0,50 < CNS < 0,54$, satisfatório.

3. RESULTADOS E DISCUSSÃO

3.1. Análise descritiva dos dados

As principais estatísticas descritivas dos dados estão sumarizadas na Tabela 2. Os máximos valores de precipitação total mensal variaram entre 518,5 e 746,3 mm para as estações de Raul Soares – Montante e Fazenda Vargem Alegre, respectivamente, sendo observados entre os meses de novembro a fevereiro. Esses resultados são coerentes com os apresentados por Lott *et al.* (2021) para a Bacia Hidrográfica do Rio Doce.

Tabela 2 - Dados da análise descritiva da precipitação média mensal e vazão média mensal.

Estações	Média (mm)	Mediana (mm)	Mín. (mm)	Máx. (mm)	DP ² (mm)	CV ³ (%)
1941011	95,36	49,05	0,00	574,50	115,46	121,08
1942002	97,25	53,15	0,00	526,50	109,13	112,21
1942006	105,31	64,55	0,00	587,00	115,19	109,39
1942031	96,01	53,70	0,00	529,20	108,91	113,43
2041048	103,55	52,60	0,00	746,30	122,82	118,61
2042008	100,09	59,75	0,00	518,50	111,15	111,06
56925100	3,96 ¹	2,81 ¹	0,40 ¹	24,21 ¹	3,33 ¹	84,29

¹ (m^3s^{-1}); ² Desvio padrão; ³ Coeficiente de variação.

Fonte: Elaborado pelos autores (2024).

A vazão média do período foi de $3,96 m^3s^{-1}$, com desvio padrão de $3,33 m^3s^{-1}$ e coeficiente de variação de 84,29%. Os altos valores do desvio padrão e coeficiente de variação dos dados indicam uma média pouco representativa e remetem a uma alta variabilidade intra-anual, com períodos de cheias seguidos por períodos de seca.

Os resultados obtidos a partir do ajuste da tendência por meio do Método dos Mínimos Quadrados Ordinários para os dados observados de precipitação total mensal e vazão média mensal são apresentados na Tabela 3. Conforme constatado, apenas a série de vazão apresentou tendência significativa, com p -valor $< 0,05$.

Pinto *et al.* (2015) analisaram a série temporal de vazões médias mensais do Rio Doce e constataram a existência de tendência, confirmada pelo teste do sinal, indicando que, além do comportamento sazonal, há um pequeno decréscimo dos valores ao longo do tempo. Já Duarte *et al.* (2019) observaram uma pequena tendência negativa na série de dados de vazão mensal para o rio Manuel Alves da Natividade, TO, que foi confirmada por meio do teste Cox-Stuart.

Tabela 3 - Coeficientes e respectivos p -valores obtidos no ajuste de tendência das séries.

Estação	Coeficiente	p -valor
1941011	-0,015	0,7942
1942002	-0,058	0,2884
1942006	-0,022	0,7049
1942031	-0,058	0,2937
2041048	0,021	0,7325
2042008	-0,022	0,692
56925100	-0,005	0,0004*

*Significância estatística ao nível de 1%.

Fonte: Elaborado pelos autores (2024).

Sendo assim, uma vez verificada a existência de tendência, o ajuste dos modelos para os dados de vazão contou com a aplicação da primeira diferenciação (d) da série original.

3.2. Identificação dos modelos e estimativa dos parâmetros

Após a análise inicial dos correlogramas das séries, foi possível propor quatro modelos SARIMA diferentes para cada estação. Os modelos propostos e os valores dos critérios de

Akaike (AIC), Hannan Quinn (HQ) e Schwarz (SW), obtidos para cada um deles, são apresentados na Tabela 4.

Tabela 4 - Modelos propostos e respectivos critérios de avaliação obtidos.

Estações	Modelos	Critérios de avaliação		
		AIC	SW	HQ
1941011	SARIMA(0,0,0)(0,1,1) ₁₂ *	4091,44	4099,14	4094,50
	SARIMA(0,0,0)(2,1,0) ₁₂	4167,67	4179,22	4172,27
	SARIMA(0,0,0)(3,1,0) ₁₂	4140,45	4155,86	4146,59
	SARIMA(1,0,1)(1,1,2) ₁₂	4087,72	4110,84	4096,93
1942002	SARIMA(0,0,0)(0,1,1) ₁₂	3987,67	3999,23	3992,27
	SARIMA(0,0,0)(2,1,0) ₁₂	4025,30	4036,85	4029,90
	SARIMA(0,0,0)(3,1,0) ₁₂	4022,92	4038,33	4029,05
	SARIMA(1,0,1)(1,1,2) ₁₂ *	3980,51	4007,48	3991,25
1942006	SARIMA(0,0,0)(0,1,1) ₁₂ *	4038,90	4046,61	4041,97
	SARIMA(0,0,0)(2,1,0) ₁₂	4092,96	4104,51	4097,56
	SARIMA(0,0,0)(3,1,0) ₁₂	4074,63	4090,04	4080,77
	SARIMA(1,0,1)(1,1,2) ₁₂	4042,54	4065,65	4051,74
1942031	SARIMA(0,0,0)(0,1,1) ₁₂ *	3987,25	3994,96	3990,32
	SARIMA(0,0,0)(2,1,0) ₁₂	4054,10	4065,65	4058,70
	SARIMA(0,0,0)(3,1,0) ₁₂	4042,42	4057,83	4048,56
	SARIMA(1,0,1)(1,1,2) ₁₂	3988,79	4011,90	3997,99
2041048	SARIMA(0,0,0)(0,1,1) ₁₂ *	4101,70	4109,41	4104,77
	SARIMA(0,0,0)(2,1,0) ₁₂	4164,96	4176,51	4169,56
	SARIMA(0,0,0)(3,1,0) ₁₂	4150,35	4165,76	4156,48
	SARIMA(1,0,1)(1,1,2) ₁₂	4108,88	4132,00	4118,09
2042008	SARIMA(0,0,0)(0,1,1) ₁₂	4018,10	4025,80	4021,17
	SARIMA(0,0,2)(0,1,1) ₁₂ *	4014,37	4025,93	4018,97
	SARIMA(0,0,0)(3,1,0) ₁₂	4068,21	4083,62	4074,34
	SARIMA(1,0,1)(1,1,2) ₁₂	4022,18	4045,29	4031,38
56925100	SARIMA(2,1,1)(1,1,1) ₁₂	1567,14	1590,24	1576,34
	SARIMA(1,1,2)(0,1,1) ₁₂ *	1566,22	1585,46	1573,88
	SARIMA(2,1,2)(1,1,1) ₁₂	1568,49	1595,43	1579,21
	SARIMA(2,1,2)(0,1,1) ₁₂	1567,14	1590,23	1576,33

*Modelo mais adequado, segundo os critérios de avaliação.

Fonte: Elaborado pelos autores (2024).

Embora tenham sido ajustados diferentes modelos para cada uma das séries de precipitação, o SARIMA(0,0,0)(0,1,1)₁₂ foi o que apresentou os menores valores dos critérios de avaliação para quatro das seis estações pluviométricas. Santos *et al.* (2021) buscaram ajustar um modelo que fornecesse melhores previsões para a precipitação pluviométrica da

cidade de Lavras – MG. De forma semelhante, os autores encontraram melhores resultados com a aplicação do SARIMA(0,0,0)(0,1,1)₁₂.

Para os dados de vazão média mensal, o modelo SARIMA(1,1,2)(0,1,1)₁₂ demonstrou ser o mais adequado. Bleidorn *et al.* (2019) modelaram e realizaram previsões de uma série temporal de vazões médias mensais do rio Jucu, no Espírito Santo, e o modelo escolhido pelos autores foi o SARIMA (1,0,0)(5,1,0)₁₂, que se mostrou adequado para realização de previsões. Duarte *et al.* (2019), por sua vez, obtiveram bons resultados ao ajustarem o modelo SARIMA(1,0,1)(1,1,4)₁₂ para modelagem e previsão de vazões mensais na bacia hidrográfica do rio Manuel Alves da Natividade, TO.

As estimativas dos parâmetros dos modelos escolhidos são apresentadas na Tabela 5. Todos os coeficientes encontrados foram significativos, excetuando-se o parâmetro Θ_1 para a estação 1942002, configurando, neste caso, um modelo do tipo incompleto.

Tabela 5 - Estimativa dos parâmetros dos modelos escolhidos para cada estação.

Estação	Parâmetro	Estimativa	Modelo	Erro Padrão
1941011	Θ_1	-1,000	$(1-B^{12}) Z_t = (1+B^{12}) a_t$	0,057
1942002	ϕ_1	-0,692	$(1+0,692B)(1+0,847B^{12})(1-B^{12}) Z_t = (1-0,658B)(1+0,012B^{12}+0,987B^{24}) a_t$	0,300
	θ_1	0,658		0,311
	ϕ_1	-0,847		0,063
	Θ_1	-0,012*		0,170
	Θ_2	-0,987		0,169
1942006	Θ_1	-0,935	$(1-B^{12}) Z_t = (1+0,935B^{12}) a_t$	0,067
1942031	Θ_1	-0,974	$(1-B^{12}) Z_t = (1+0,974B^{12}) a_t$	0,088
2041048	Θ_1	-1,000	$(1-B^{12}) Z_t = (1+B^{12}) a_t$	0,099
2042008	θ_1	0,059	$(1-B^{12}) Z_t = (1+B^{12})(1-0,059B-0,135B^2) a_t$	0,053
	θ_2	0,135		0,055
	Θ_1	-1,000		0,051
56925100	ϕ_1	0,636	$(1-0,636B)(1-B)(1-B^{12}) Z_t = (1+0,941B^{12})(1+1,1B-0,124B^2) a_t$	0,078
	θ_1	-1,100		0,095
	θ_2	0,124		0,088
	Θ_1	-0,941		0,057

*Não significativo ao nível de 5%.

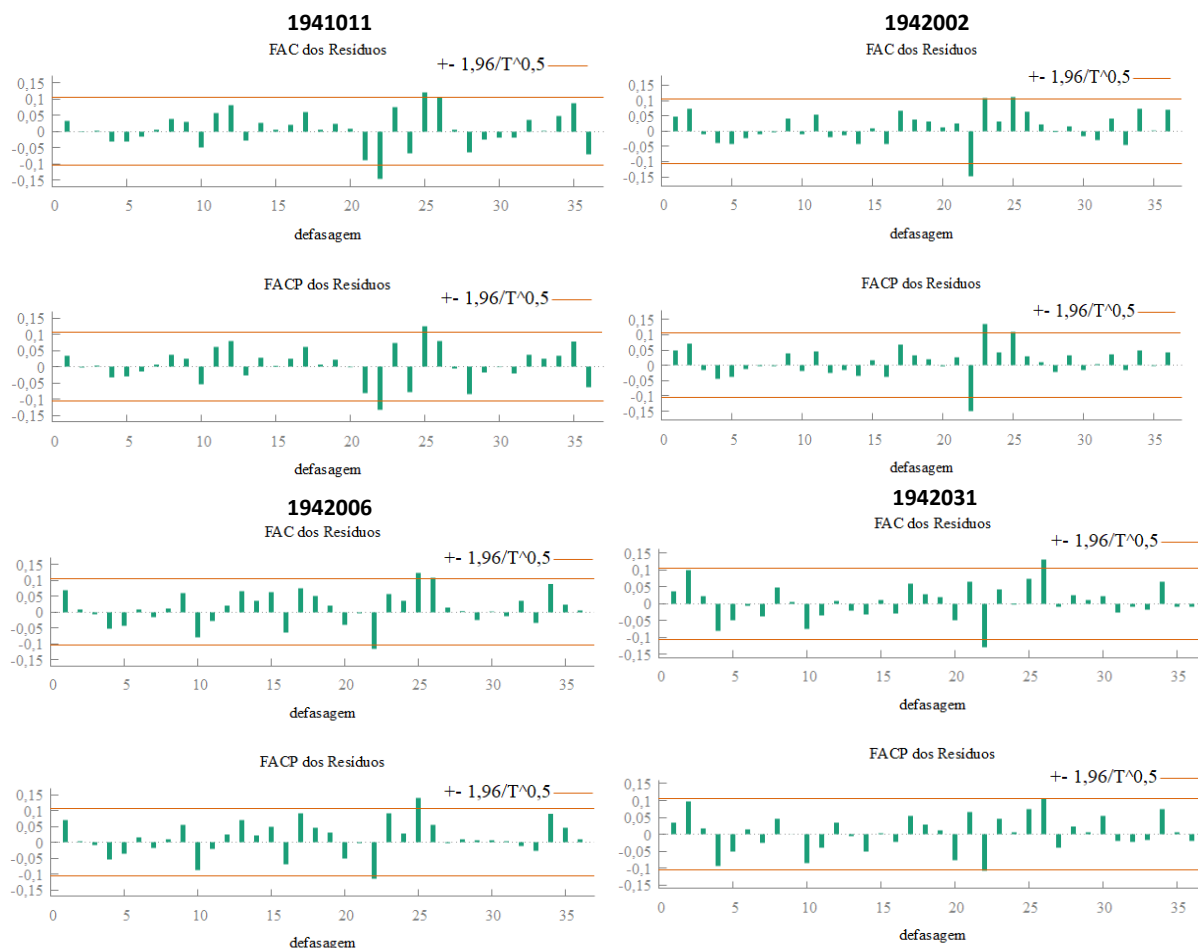
Fonte: Elaborado pelos autores (2024).

3.3. Diagnóstico dos modelos

Os correlogramas residuais dos modelos considerados mais adequados para cada série estão apresentados na Figura 3. Por meio da análise residual, não foi observada correlação significativamente diferente de zero, sobretudo nas primeiras defasagens. Este fato indica um ajuste adequado dos modelos e que estes conseguiram captar toda a correlação serial existente.

Associada à análise visual, por meio do teste de Box-Pierce (Lobato; Nankervis e Savin, 2001), os p-valores, para todos os correlogramas, encontraram-se acima de 5%, considerando $k = 36$ lags, ou seja, não se rejeita a hipótese nula de que as k primeiras autocorrelações dos ruídos são iguais a zero. Segundo Morettin e Toloi (2006), a análise residual permite validar os modelos para realização de previsões. Nesse sentido, os modelos escolhidos neste estudo foram considerados adequados para tal.

Figura 3 - Correlogramas dos resíduos dos modelos ajustados para cada série.



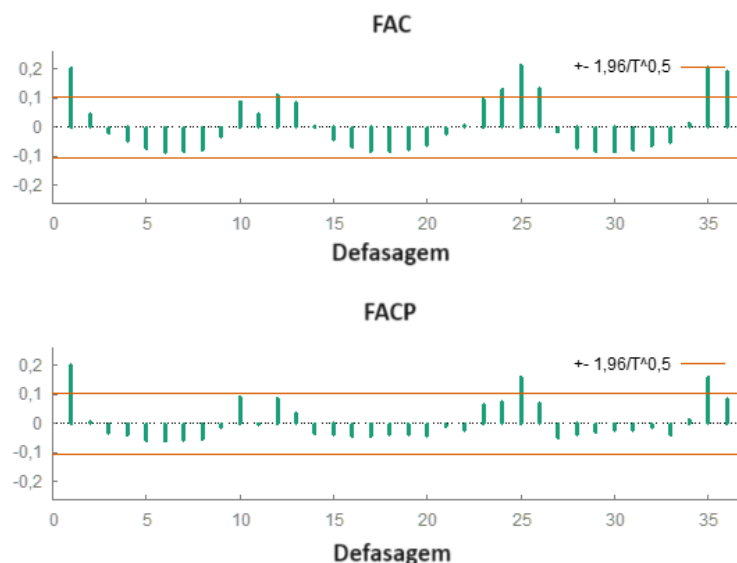


Fonte: Elaborado pelos autores (2024).

3.4. Análise da volatilidade

A partir do correlograma dos resíduos quadrados do modelo SARIMA(1,1,2)(0,1,1)₁₂ ajustado à série de vazão (Figura 4), foi possível observar correlação temporal restante, devido à presença de *lags* significativamente diferentes de zero ($p < 0,05$).

Figura 4 - Correlograma dos resíduos quadrados do modelo SARIMA(1,1,2)(0,1,1)₁₂, ajustado à série de vazão.



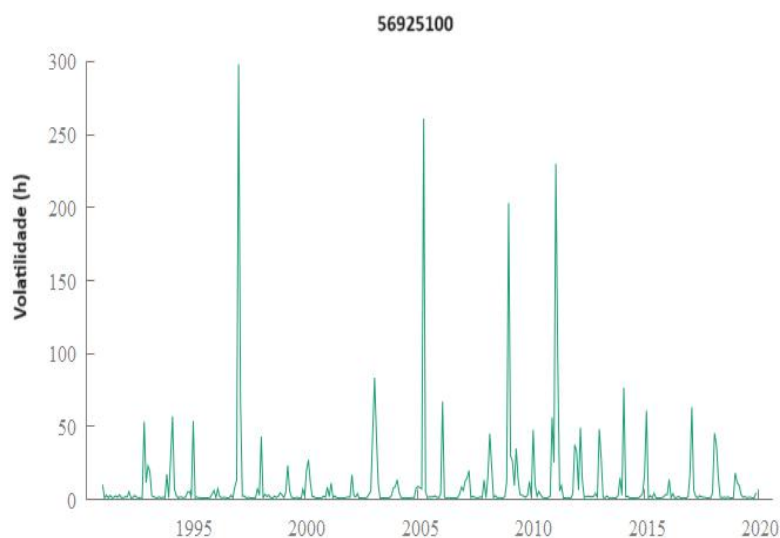
Fonte: Elaborado pelos autores (2024).

Dessa forma, a análise da FACP indicou o ajuste de um modelo do tipo ARCH(1) aos resíduos, com a volatilidade expressa por:

$$h_t = 1,05 + 1,835X^2_{t-1} \quad (4)$$

O gráfico da volatilidade da série de vazões é apresentado na Figura 5, onde é possível observar agrupamentos para os anos de 1997, 2005, 2009 e 2011.

Figura 5 - Volatilidade presente na série de vazões mensais da estação 56925100.



Fonte: Elaborado pelos autores (2024).

Segundo Alexander (2005), o valor encontrado para o parâmetro α_1 (1,835) pode ser considerado elevado. Altos coeficientes α remetem a uma volatilidade que reage de forma abrupta aos movimentos do fenômeno estudado, e, assim, o gráfico tende a apresentar picos mais pontiagudos, conforme pode ser observado na Figura 5. Feliciani (2013) realizou a previsão de vazões para o rio Juguari, localizado na região Sul do Brasil, e obteve um baixo valor de α para o ajuste de um modelo ARCH(1) aos resíduos do SARIMA(1,0,0)(2,0,0)₁₂. O autor comenta que baixos valores para esse parâmetro indicaram, neste caso, que as vazões retornam ao seu padrão anual de variabilidade em um curto espaço de tempo.

A partir de uma investigação na literatura, visando explicar a ocorrência das volatilidades observadas na Figura 5, foi averiguado que o pico referente ao ano de 1997 pode ter ocorrido em resposta aos eventos de cheia na bacia, segundo o histórico obtido a partir do Sistema de Alerta Hidrológico do Rio Doce (Coelho Filho; Matos e Motta, 2021). Segundo o IGAM (2014), no ano de 1997, a precipitação acumulada para a bacia foi 34% maior que a normal climatológica, evidenciando a presença de uma anomalia climática, fato que refletiu nas vazões observadas.

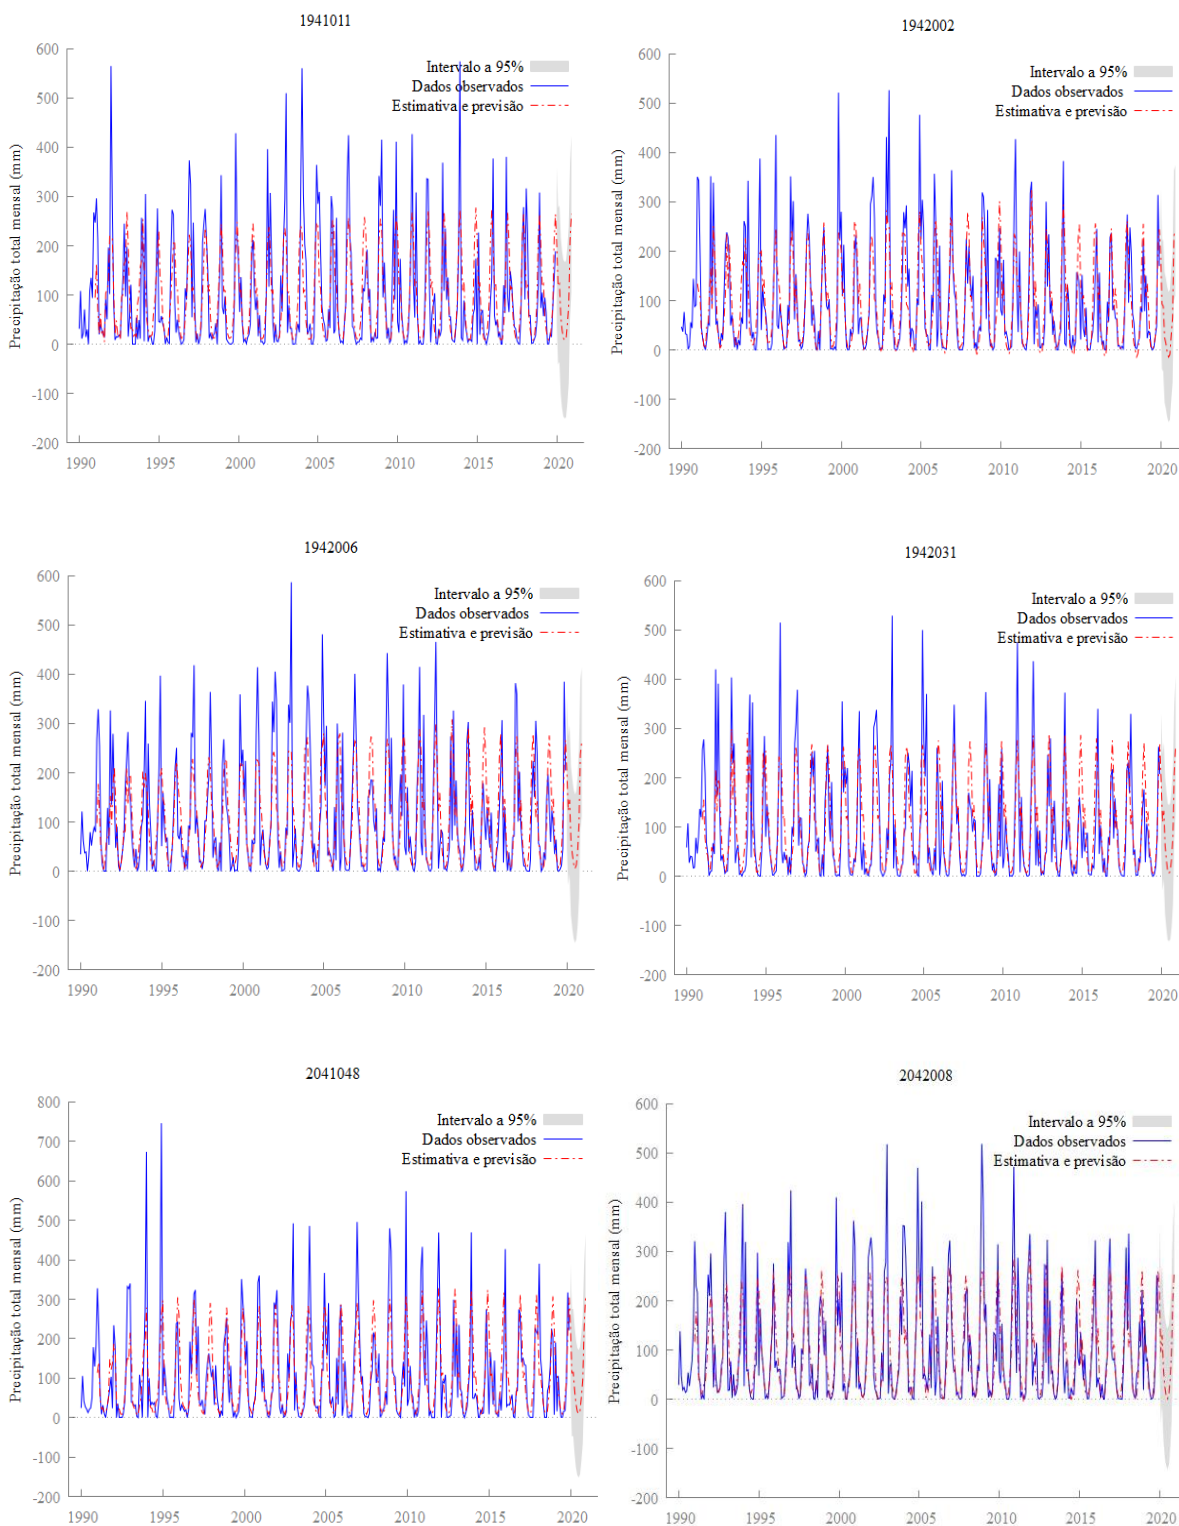
Costa (2007) e Alves (2023), por sua vez, avaliaram as áreas de risco à inundação no perímetro urbano de Caratinga e relataram os eventos extremos de precipitação ocorridos na bacia em 2004 e 2005, que ocasionaram, além dos prejuízos financeiros, perdas de vidas humanas. Nesse período, alguns eventos chegaram a acumular 200 mm em 24 horas, fazendo com que o Rio Caratinga subisse 8 m acima no nível normal.


Já Fialho (2013) ressaltou o comportamento da precipitação em Minas Gerais para o período chuvoso dos anos hidrológicos de 2008/2009 e 2010/2011, que foram considerados atípicos por apresentarem valores 30% acima da média histórica. O autor comenta que, na região do Alto Rio Doce, muitos municípios foram acometidos por problemas de enchentes ocorridas em resposta aos eventos extremos de chuva.

3.5. Previsões

Os gráficos das previsões realizadas para cada uma das estações são apresentados na Figura 6.

Figura 6 - Dados observados e estimados para o período de 1990-2019 e previsões realizadas para o ano de 2020 em cada estação.





Fonte: Elaborado pelos autores (2024).

Embora a análise residual tenha validado a aplicação dos modelos para a realização das previsões, a partir de uma breve visualização dos gráficos, é possível observar uma certa dificuldade destes em captar os picos das séries. De acordo com Viola *et al.* (2009), tal fato pode ser explicado pela complexidade das variáveis hidrológicas, sobretudo a vazão, que depende diretamente da gênese do escoamento superficial direto.

Além disso, os modelos de séries temporais têm limitações para capturar eventos extremos, pois suas suposições de linearidade e estacionariedade não abordam adequadamente a complexidade e a variabilidade destes fenômenos climáticos pontuais. Isso porque esses modelos dependem de relações lineares e não conseguem representar as interações e dependências não lineares típicas de eventos extremos, especialmente em cenários de mudanças climáticas (Bopp; Shaby; Huser, 2020; Meresa; Tischbein; Mekonnen, 2022).

Entretanto, observa-se que o modelo de vazão ajustado foi eficaz na representação e previsão dos períodos de estiagem, com boa aderência às vazões mínimas observadas. Em conformidade com a análise visual, Brito *et al.* (2021) também constataram a subestimação da vazão de pico observada ao empregarem o modelo SARIMA em uma bacia hidrográfica na região oeste de Cuba. Segundo os autores, o modelo apresentou bom desempenho na previsão de períodos de seca devido à menor variabilidade mensal da precipitação na região, principalmente para intervalos de previsão mais longos.

A identificação da componente sazonal em períodos de recessão do escoamento permite a obtenção de vazões mínimas de referência e, conseqüentemente, o controle e otimização do uso de recursos hídricos (Pinto *et al.*, 2015). Nesse sentido, as informações geradas por este estudo podem ser consideradas uma ferramenta potencial para a gestão da bacia hidrográfica, servindo como subsídio ao conhecimento da disponibilidade hídrica nos períodos de estiagem (Pereira *et al.*, 2016).

Os valores dos coeficientes estatísticos utilizados para avaliação do desempenho de cada modelo são apresentados na Tabela 6.

Tabela 6 - Coeficientes estatísticos utilizados para avaliação do desempenho dos modelos.

Estações	RMSE (mm)	r	C _{NS}
1941011	82,09	0,71	0,50
1942002	68,56	0,78	0,61
1942006	76,50	0,75	0,56
1942031	71,26	0,76	0,58
2041048	82,84	0,74	0,55
2042008	73,26	0,76	0,57
56925100	2,29*	0,74	0,54

*(m³s⁻¹).

Fonte: Elaborado pelos autores (2024).

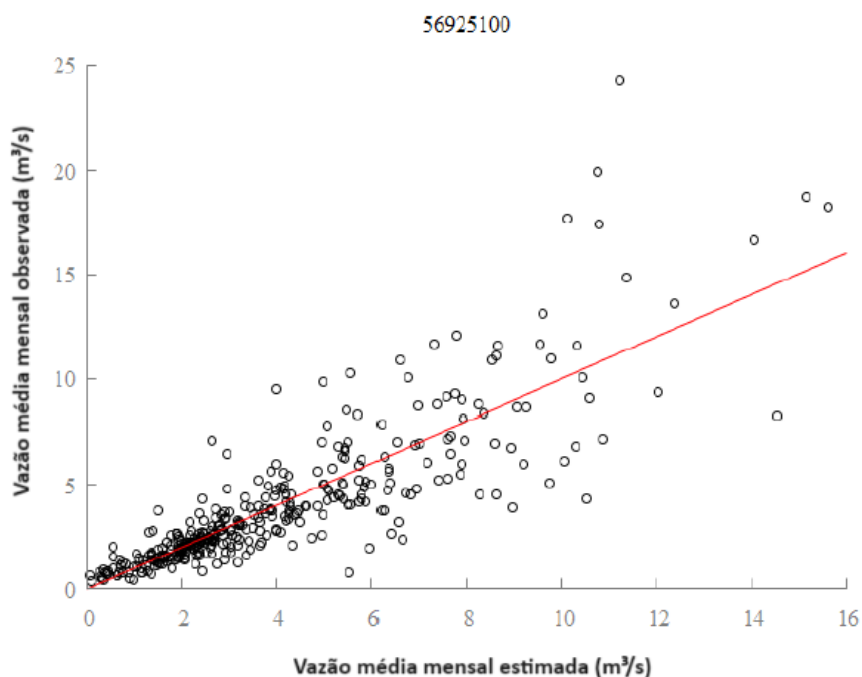
Os valores do RMSE variaram entre 68,5 e 82,8 mm para as estações pluviométricas Bom Jesus do Galho (1942002) e Fazenda Vargem Alegre (2041048), respectivamente. Quanto ao coeficiente r, para todas as estações, as correlações foram significativas e classificadas como muito altas ($0,7 < r < 0,9$), segundo Hopkins (2016). Já os valores de CNS variaram entre 0,50 e 0,61, para as estações pluviométricas Santo Antônio do Manhuaçu e Bom Jesus do Galho, respectivamente. Conforme a classificação de Moriasi *et al.* (2007), todos os modelos apresentaram desempenho satisfatório ($0,50 < CNS < 0,54$), com exceção do SARIMA(1,0,1)(1,1,2)₁₂ para a estação Bom Jesus do Galho (1942002), que forneceu um bom desempenho no ajuste ($0,54 < CNS < 0,65$).

Bayer *et al.* (2012) utilizaram a modelagem e previsão de vazões médias mensais na região noroeste do estado Rio Grande do Sul utilizando o SARIMA(3,0,0)(2,1,2)₁₂. O modelo

forneceu um bom ajuste à série de vazões observadas, com um CNS de 0,68. Já Duarte *et al.* (2019) obtiveram um CNS de 0,81 ao ajustarem o modelo SARIMA(1,0,1)(1,1,4)₁₂ para previsão de vazões em uma bacia do estado do Tocantins. Semelhantemente, Khodakhah *et al.* (2022) ao analisarem diferentes modelos de previsão da vazão mensal em bacias hidrográficas do Irã, concluíram que o modelo SARIMA(1,0,0)(3,1,4)₁₂ forneceu previsões mais precisas, com CNS de 0,83, principalmente para períodos de estiagem.

Para fins de exemplificação, a correlação entre os dados observados e os estimados pelo modelo SARIMA(1,1,2)(0,1,1)₁₂ para série de vazões médias mensais é apresentada na Figura 7.

Figura 7 - Correlação entre os dados de vazão média mensal observados e estimados pelo modelo SARIMA(1,1,2)(0,1,1)₁₂ para a estação fluviométrica Caratinga (56925100).



Fonte: Elaborado pelos autores (2024).

Na referida figura, verifica-se uma maior dispersão da nuvem de dados ao redor da reta 1:1 para maiores valores de vazão. Porém, de maneira geral, os dados estimados se aproximam dos observados para os menores valores, evidenciando a capacidade do modelo em captar as vazões mínimas características dos períodos de recessão, conforme pode ser

visualizado na Figura 6. No âmbito desta discussão, este estudo poderá servir como uma ferramenta à implementação de estratégias preventivas para a gestão dos recursos hídricos em aspectos relacionados à segurança hídrica e à mitigação dos impactos negativos, sobretudo nos períodos de estiagem.

4. CONSIDERAÇÕES FINAIS

O modelo SARIMA(0,0,0)(0,1,1)₁₂ foi considerado o mais adequado para análise de quatro das seis séries de precipitação mensal (1990-2019). Para os dados de vazão mensal, referentes ao mesmo período, o SARIMA(1,1,2)(0,1,1)₁₂ forneceu melhores resultados. A partir da análise residual, os modelos foram considerados adequados para a realização das previsões para o ano de 2020.

Todos os modelos apresentaram dificuldade em captar os picos das séries, tanto de precipitação, quanto vazão. Por outro lado, para a série de vazão, o SARIMA(1,1,2)(0,1,1)₁₂ foi eficaz na representação dos períodos de recessão, com boa aderência às vazões mínimas observadas. Nesse sentido, pode ser apontado uma ferramenta para o planejamento e gestão dos recursos hídricos, contribuindo para o conhecimento da disponibilidade hídrica na região.

Como as séries não possuem outras variáveis explicativas, o desempenho dos modelos ajustados pode ser considerado satisfatório, uma vez que a modelagem contou apenas com a correlação serial dos dados, considerando as componentes sazonais, autorregressivas e de médias móveis.

AGRADECIMENTOS

Os autores agradecem à CAPES pelo apoio financeiro ao programa de Pós-graduação em Recursos Hídricos da Universidade Federal de Lavras, MG (Financiamento de código 001).

REFERÊNCIAS

- AKAIKE, H. A new look at the statistical model identification IEEE transactions on automatic control. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716–723, 1974.
- AL BALASMEH, O.; BABBAR, R.; KARMAKER, T. Trend analysis and ARIMA modeling for forecasting precipitation pattern in Wadi Shueib catchment area in Jordan. **Arabian Journal of Geosciences**, v. 12, 2019.
- ALBERTON, G. B. *et al.* Aplicação de redes neurais artificiais para previsão de enchentes no Rio Itajaí-Açu em Blumenau, SC, Brasil. **Revista Ibero-Americana de Ciências Ambientais**, v. 12, n. 4, p. 686–696, 2021.
- ALEXANDER, C. **Modelos de Mercados**: um guia para a análise de informações financeiras. São Paulo: Bolsa de Mercadorias e Futuros, 2005.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ALVES, T. S. **Elaboração de modelagem hidrológica e hidráulica de parte da bacia do rio Caratinga para determinação da área urbana inundável no município de Caratinga-MG: estudo de caso no rio Caratinga, Minas Gerais**. 2023. Dissertação (Mestrado) - Universidade Federal de Itajubá, Itabira, 2023.
- ANA. **Hidroweb**. Brasília: Agência Nacional de Águas e Saneamento Básico, [2022]. Disponível em: <http://www.snirh.gov.br/hidroweb/serieshistoricas>. Acesso em: 8 ago. 2022.
- ARAÚJO, A. S.; SILVA, A. R.; ZÁRATE, L. E. Extreme precipitation prediction based on neural network model – A case study for southeastern Brazil. **Journal of Hydrology**, v. 606, p. 127454, 2022.
- BAYER, D. *et al.* Modelagem e Previsão de Vazões Médias Mensais do Rio Potiribu Utilizando Modelos de Séries Temporais. **Revista Brasileira de Recursos Hídricos**, v. 17, n. 2, p. 229–239, 2012.
- BEZERRA, A. P. *et al.* Modelagem preditiva da precipitação para análise das inundações e suas consequências no município de Natal - RN. **Revista GEAMA - Ciências Ambientais e Biotecnologia**, v. 9, n. 1, p. 29–41, 2023.
- BLEIDORN, M. T. *et al.* Modelagem e previsão de vazões médias mensais do Rio Jucu, ES, utilizando o modelo SARIMA. **Irriga**, v. 24, n. 2, p. 320–335, 2019.
- BOPP, G. P.; SHABY, B. A.; HUSER, R. A Hierarchical Max-Infinitely Divisible Spatial Model for Extreme Precipitation. **Journal of the American Statistical Association**, v. 116, n. 533, p. 93–106, 2020.
- BOX, G. P.; JENKINS, G. M. **Time series analysis, forecasting and control**. San Francisco: Holden-Day, 1976.
- BRITO, G. R. A. *et al.* Comparison between SARIMA and Holt–Winters models for forecasting

monthly streamflow in the western region of Cuba. **SN Applied Sciences**, v. 3, n. 6, 2021.

COELHO FILHO, J. A. P.; MATOS, A. J. S.; MOTTA, B. G. **Sistema de alerta hidrológico da bacia do Rio Doce**. Belo Horizonte: Companhia de Pesquisa de Recursos Minerais - CPRM, 2021.

COSTA, M. D. G. A. **Avaliação de áreas de risco à inundação no perímetro urbano de Caratinga, MG através do uso de dados altimétricos provenientes dos sensores erotransportado Lidar**. 2007. Dissertação (Mestrado)— Universidade Federal de Viçosa, Viçosa, 2007.

COTTRELL, A.; LUCCHETTI, R. **Gretl User's Guide: GNU Regression, Econometrics and Time-Series Library**. Ancona: Università Politecnica delle Marche, [2022]. Disponível em: <http://gretl.sourceforge.net/gretl-help/gretl-guide.pdf>. Acesso em: 20 nov. 2022.

CPRM. **Mapa geológico do estado de Minas Gerais**. Brasília: Companhia de Pesquisa de Recursos Minerais, [2020]. Disponível em: <<https://rigeo.sgb.gov.br/handle/doc/21828>>. Acesso em: 18 nov. 2024.

DUARTE, V. B. R. *et al.* Previsão de vazão na bacia hidrográfica do rio Manuel Alves da Natividade utilizando o modelo de séries temporais SARIMA. **Journal of Biotechnology and Biodiversity**, v. 7, n. 4, p. 457–468, 2019.

ENGLE, R. F. Autorregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987–1007, 1982.

FELICIANI, A. V. **Previsão de vazões de afluência para o setor elétrico por meio de modelos lineares e não lineares**. 2013. Dissertação (Mestrado) — Universidade Federal de Santa Maria, Santa Maria, 2013.

FIALHO, E. S. Climatologia E Desastres Ambientais: a Demanda Dos Recursos Públicos Após O Espetáculo Midiático. **Revista Tamoios**, v. 9, n. 1, p. 42–62, 2013.

HANNAN, E. J.; QUINN, B. G. The determination of the order of an autoregression. **Journal of the Royal Statistical Society**, v. 41, p. 190–195, 1979.

HOPKINS, W. G. **A New View of Statistics**. Middlesbrough: Internet Society for Sport Science, 2016.

IDE-SISEMA. **Infraestrutura de dados espaciais**. Belo Horizonte: Sistema Estadual de Meio Ambiente e Recursos Hídricos, [2024]. Disponível em: <<https://idesisema.meioambiente.mg.gov.br/webgis>>. Acesso em: 18 nov. 2024.

IGAM. **Informativo Nº 4 - Bacia do Rio Doce**. Belo Horizonte: Instituto Mineiro de Gestão das Águas, 2014.

IGAM. **Plano de ação de Recursos Hídricos da Unidade de Planejamento e Gestão dos Recursos Hídricos Caratinga**. Caratinga: Instituto Mineiro de Gestão das Águas, 2010.

INMET. **Série Histórica: Banco de dados meteorológicos**. Brasília: Instituto Nacional de Meteorologia, [2022]. Disponível em: <https://portal.inmet.gov.br/>. Acesso em: 14 nov. 2022.

JANARTHANAN, R. *et al.* Prediction of rainfall using fuzzy logic. **Materials Today: Proceedings**, v. 37, p. 959–963, 2021.

KHODAKHAH, H. *et al.* Comparing linear and non-linear data-driven approaches in monthly river flow prediction, based on the models SARIMA, LSSVM, ANFIS, and GMDH. **Environmental Science and Pollution Research**, v. 29, n. 15, p. 21935–21954, 2022.

LIMA, L. P. A. *et al.* Utilização de estatística descritiva e de modelo SARIMA no estudo de precipitação na região sudeste de Mato Grosso. **Revista de Ciências Ambientais - RCA**, v. 14, n. 1, 2020.

LOBATO, I.; NANKERVIS, J. C.; SAVIN, N. E. Testing for autocorrelation using a modified Box-Pierce Q test. **International Economic Review**, v. 42, n. 1, p. 187–205, 2001.

LOTT, B. A. *et al.* Chuvas na Bacia Hidrográfica do Rio Doce – MG/ES no primeiro trimestre de 2020. **Sociedade, Tecnologia e Meio Ambiente: avanços, retrocessos e novas perspectivas**, p. 110–126, 2021.

MACHADO, L. A.; ASSIS, W. L. Comparação entre métodos de preenchimento de falhas em séries de dados meteorológicos da bacia hidrográfica do Rio das Velhas (MG). **Geografias**, v. 14, n. 1, p. 73–90, 2018.

MARTINS, F. B. *et al.* Classificação climática de Köppen e de Thornthwaite para Minas Gerais: Cenário atual e projeções futuras. **Revista Brasileira de Climatologia**, v. 22, p. 149–164, 2018.

MASUM, M. H. *et al.* Time Series Prediction of Rainfall and Temperature Trend using ARIMA Model. **Journal of Scientific Research**, v. 14, n. 1, p. 215–227, 2022.

MEDEIROS, E. S. *et al.* Estudo das chuvas máximas diárias no município de Barreiras/BA por meio da metodologia de séries temporais. **Revista da Universidade Vale do Rio Verde**, v. 18, n. 1, p. 287–295, 2020.

MERESA, H.; TISCHBEIN, B.; MEKONNEN, T. Climate change impact on extreme precipitation and peak flood magnitude and frequency: observations from CMIP6 and hydrological models. **Natural Hazards**, v. 111, n. 3, p. 2649–2679, 2022.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: ABE - Projeto Fisher – Blucher, 2006.

MORIASI, D. N. *et al.* Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **American Society of Agricultural and Biological Engineers**, v. 50, n. 3, p. 885–900, 2007.

OLIVEIRA, M. R. G. *et al.* Estudo estatístico do coeficiente de escoamento superficial da bacia hidrográfica do riacho Jacu no Sertão do Pajeu – PE. **Rev. Bras. Biom**, v. 33, n. 3, p. 277–290, 2015.

PEREIRA, D. R. *et al.* Desempenho de um modelo hidrológico concentrado e de um semidistribuído na predição de vazões diárias. **Irriga**, v. 21, n. 2, p. 409–424, 2016.

PINTO, W. D. P.; LIMA, G. B.; ZANETTI, J. B. 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. 3, p. 1–11, 2015.

RAWAT, D. *et al.* Modeling of rainfall time series using NAR and ARIMA model over western Himalaya, India. **Arabian Journal of Geosciences**, v. 15, n. 1696, 2022.

RUEZZENE, C. B. *et al.* Preenchimento de falhas em dados de precipitação através de métodos tradicionais e por inteligência artificial. **Revista Brasileira de Climatologia**, v. 29, p. 177–204, 2021.

SANTOS, H. G. *et al.* **Sistema brasileiro de classificação de solos**. 5. ed. Brasília: Embrapa, 2018.

SANTOS, P. H. A. B. *et al.* Ajuste de um modelo de séries temporais para prever a precipitação pluviométrica. **Research, Society and Development**, v. 10, n. 6, p. e41810615643, 2021.

SCHWARZ, G. E. Estimating the dimension of a model. **Annals of Statistics**, v. 6, n. 2, p. 461–464, 1978.

VIOLA, M. R. *et al.* Modelagem hidrológica na bacia hidrográfica do Rio Aiuruoca, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 5, p. 581–590, 2009.

ZAHARAN, B. *et al.* A fuzzy based model for rainfall prediction Bilal. **International Journal of Data and Network Science**, v. 7, p. 97–106, 2023.