

Artigo

Modelagem Estocástica de Séries Temporais Pluviométricas e Fluviométrica da Bacia Hidrográfica do Rio Preto, Sudeste do Brasil

Mateus Henrique Barbosa¹ , Marcela de Marilac Carvalho² , Thelma Sáfiadi² ,
Luiz Fernando Coutinho de Oliveira¹ 

¹*Departamento de Recursos Hídricos, Escola de Engenharia, Universidade Federal de Lavras, Lavras, MG, Brasil.*

²*Departamento de Estatística, Instituto de Ciências Exatas e Tecnológicas, Universidade Federal de Lavras, Lavras, MG, Brasil.*

Recebido em: 13 de Junho de 2023 - Aceito em: 29 de Outubro de 2024

Resumo

O presente trabalho objetivou obter um modelo para as séries temporais de vazão e precipitação, do grupo SARIMA, de dados observados em cinco estações pluviométricas e em uma estação fluviométrica, presentes na Bacia Hidrográfica do Rio Preto (BHRP), a fim de selecionar o melhor modelo que represente seu caráter preditivo. O modelo selecionado para os dados de precipitação total mensal (PTM), considerando os critérios de seleção de Akaike, Schwarz e Hannan e Quinn, foi o SARIMA (0,0,0)x(0,1,1), e o modelo selecionado para os dados de vazão mensal foi o SARIMA (1,0,0)x(0,1,1). Os modelos do tipo SARIMA demonstram boa capacidade em modelar e prever os dados de precipitação e vazão de uma bacia hidrográfica com relevo e sistemas atmosféricos heterogêneos. Esses modelos foram capazes de incorporar as características, como a sazonalidade e a correlação serial, e demonstraram bons ajustes aos dados, qualificando-os para a realização de previsões de longo termo, que foram feitas em um horizonte de 84 meses.

Palavras-chave: SARIMA, sazonalidade, precipitação, vazão, séries temporais.

Stochastic Modeling of Rainfall and Fluviometric Time Series of the Rio Preto Basin, Southeastern Brazil

Abstract

The present work aimed to obtain a model for the time series of flow and precipitation, of the SARIMA group, from data observed in 5 pluviometric stations and a fluviometric station, present in the Rio Preto Hydrographic Basin (BHRP), to select the best model that represent its predictive character. The model selected for the monthly total precipitation (PTM) data, considering the selection criteria of Akaike, Schwarz and Hannan and Quinn, was SARIMA (0,0,0)x(0,1,1), and the selected model for monthly flow data it was SARIMA (1,0,0)x(0,1,1). SARIMA models demonstrate good capacity to model and predict precipitation and flow data from a river basin with heterogeneous relief and atmospheric systems. The models were able to incorporate characteristics such as seasonality and serial correlation, and demonstrated good adjustments to the data, qualifying them for long-term forecasts, which were made over a horizon of 84 months.

Keywords: SARIMA, seasonality, precipitation, flow, time series.

1. Introdução

As séries temporais hidrológicas normalmente apresentam comportamentos cíclicos interanuais, assumindo valores médios distintos em cada estação do ano. Esse

fenômeno, denominado sazonalidade (Bayer e Castro, 2012), é comumente presente em dados ambientais e tem significativa importância no gerenciamento dos recursos hídricos.

Em particular, no caso das chuvas e vazões, a compreensão da periodicidade interanual é fundamental para aferir comportamentos futuros. Para efeitos de previsão, evidencia-se a importância do efeito da sazonalidade na modelagem destas variáveis observadas ao longo do tempo, de modo a prever a ocorrência de eventos extremos, como inundações e secas, possibilitando a tomada de medidas preventivas e mitigadoras de seus impactos.

Eventos extremos de precipitação podem levar à ocorrência de enchentes, inundações e deslizamentos de encostas. Todos esses fenômenos são responsáveis por perda de vidas, bens materiais, catástrofes ambientais, além de danos sociais e econômicos, cujos impactos podem ser minimizados, caso sejam estudados e previstos, favorecendo a adoção de medidas preventivas.

Todos os anos, eventos de precipitação de grande magnitude impactam todo o Brasil, principalmente a região Sudeste, causando uma série de danos. Os sistemas climáticos mais frequentes e predominantes atuantes na região e que influenciam os eventos de precipitação são a Massa Tropical Atlântica, a Massa Polar Atlântica e os sistemas frontais, que podem alterar a temperatura do ar provocando a ocorrência de precipitações, assim como a atuação da Zona de Convergência do Atlântico Sul, que devido à umidade proveniente da região Amazônica e do oceano Atlântico Sul, é responsável pelas precipitações durante o verão austral (Ferreira, 2002; Oliveira, 2016; Ferreira e Reboita, 2022).

A Bacia Hidrográfica do Rio Preto (BHRP), situada no Sudeste do Brasil, entre os estados de Minas Gerais e Rio de Janeiro, é um importante afluente da Bacia Hidrográfica do Rio Paraíba do Sul, uma região de grande relevância industrial e agropecuária que abrange 37 cidades; e, sob condições normais de pluviosidade, apresenta um menor risco de cheias. Entretanto, seu relevo acidentado, associado a solos rasos e à remoção da cobertura vegetal devido à expansão urbana, pode favorecer a formação de enchentes (Olszevski, 2011).

A expansão agropecuária e industrial ao longo da BHRP faz com que aproximadamente 70% da cobertura do solo da bacia seja de agricultura e solo exposto, além do aumento das áreas urbanizadas nos últimos anos (Oliveira, 2016). Essa combinação de fatores é responsável por causas como a impermeabilização do solo, remoção de vegetação nativa, erosão e perda de solo e alteração do leito de rios, proporcionando maiores chances de ocorrência de enchentes, deslizamentos e inundações devido ao transbordamento de rios.

Oliveira *et al.* (2022), ao analisarem um episódio atípico ocorrido em janeiro de 2007 na BHRP, demonstraram que, embora 2007 seja identificado como um ano seco, o mês de janeiro do referido ano registrou acumulados mensais superiores a 250,9 mm, fazendo com que esse mês fosse classificado como um dos maiores registros de precipitação desde 1961, para a BHRP e para outras regiões do

Sudeste e Centro-Oeste do Brasil. Esse episódio foi responsável pela ocorrência de enchentes, inundações, deslizamentos de terra, além de adversidades que afetaram a população localizada na BHRP (Oliveira, 2016).

A previsibilidade dos problemas descritos anteriormente pode apoiar a tomada de decisão sobre os recursos hídricos, de modo a embasar ações que possibilitem a mitigação dos danos relacionados a esses eventos. Dada a relevância de modelar a sazonalidade inerente das séries temporais de vazão e precipitação, o modelo SARIMA (Autoregressivo Integrado de Médias Móveis com Sazonal) proposto por Box e Jenkins (1976), tem-se mostrado uma importante ferramenta para pesquisadores e gestores (Sáfadi, 2004; Santo e Oliveira, 2016; Tadesse e Dinka, 2017; Bleidorn *et al.*, 2019; Duarte, 2019).

Aplicações do modelo SARIMA para a previsão da precipitação são evidenciadas nos trabalhos de Pereira *et al.* (2015) e Santos *et al.* (2021), e para a previsão de vazões nos trabalhos de Sáfadi (2004) e Duarte *et al.* (2019), alcançando resultados satisfatórios, baixos indicadores de erros e resíduos com características de ruído branco.

Outras aplicações de modelos SARIMA que demonstram grande utilidade na área ambiental são as referentes à análise da temperatura média do ar (Cintra *et al.*, 2019; Menezes Filho, 2020; Caixeta *et al.*, 2021) e umidade relativa do ar (Tibulo *et al.*, 2018; Moraes *et al.*, 2020), assim como para eventos que ocorrem devido a fatores climáticos, como focos de calor (Espinosa *et al.*, 2010) e incidência de dengue (Dos Santos, 2017; Medeiros, 2018).

Santos *et al.* (2021) estudaram a série histórica de precipitação média mensal da cidade de Lavras-MG, com o objetivo de obter um modelo estatístico que permitisse fazer previsões. Para tanto, foram utilizados os dados observados entre os meses de janeiro de 2000 a dezembro de 2018. Foram ajustados alguns modelos da classe SARIMA, sendo o modelo SARIMA (0,0,0) x(0,1,1)₁₂, aquele com o melhor ajuste, produzindo uma previsão para os doze meses do ano de 2019, com valores dentro do intervalo de confiança de 95%, apesar dos fatores climáticos que envolvem a variável em questão.

Caixeta, Filho e Fonseca (2021) avaliaram modelos da classe SARIMA, a fim de obter uma equação para realizar previsões da vazão média mensal de uma sub-bacia do Rio Paranaíba, situada na região do Alto Paranaíba-MG. Para isso foram utilizados dados da série histórica de vazão média mensal, entre janeiro de 2003 e dezembro de 2014. O modelo SARIMA (2,1,2)x(1,0,0)₁₂ apresentou o melhor ajuste aos dados, pelo critério de seleção de Akaike e pelo critério de informação Bayesiana. Entretanto, os autores observaram que a previsão para seis meses do ano de 2014 não foi adequada. Eles justificam essa ocorrência devido à escassez hídrica ocorrida nesse ano, indicando que o modelo pode não ser capaz de prever períodos de estiagem.

Menezes Filho (2020) avaliou a obtenção de um modelo do tipo SARIMA para obter a previsão da temperatura média mensal da cidade de Rio Paranaíba-MG. Para isso foi utilizada a série histórica de 17 anos, entre janeiro de 2002 e dezembro de 2018, para o ajuste do modelo. O modelo que apresentou o melhor ajuste aos dados, pelo critério de seleção de Akaike e pelo critério de informação Bayesiana, foi o SARIMA (0,1,2)x(3,1,0)₁₂, reproduzindo de forma satisfatória a série temporal, demonstrando que a metodologia é adequada para dados climatológicos.

Diante desse cenário, embora alguns estudos tenham reportado dificuldades no uso de modelos SARIMA para prever séries temporais de vazão e precipitação (Caixeta *et al.*, 2021; Santos *et al.*, 2021), devido à influência de fatores como localização, meteorologia e condições geográficas, esses modelos ainda demonstram relevância na redução das imprecisões da variabilidade hidrológica e climática em diversas regiões. A escolha de utilizar o modelo SARIMA neste trabalho se justifica pela sua flexibilidade e capacidade de modelar sazonalidades complexas, o que torna esses modelos adequados para regiões com padrões hidroclimáticos complexos.

Assim, utilizando critérios de seleção e métodos de validação para selecionar um modelo parcimonioso que garanta a precisão das previsões, este trabalho tem como objetivo obter previsões de longo prazo de dados mensais de precipitação de cinco estações pluviométricas e de vazão da Bacia Hidrográfica do Rio Preto, situada entre os estados de Minas Gerais e Rio de Janeiro, sudeste do Brasil, com o uso de modelos SARIMA.

Com este estudo é possível entender a variabilidade espaço-temporal da vazão e da precipitação, fornecendo previsões úteis necessárias para auxiliar na tomada de decisão, o que é fundamental para um adequado planejamento e gerenciamento estratégico futuro dos recursos hídricos.

2. Materiais e Métodos

2.1. Dados e área de estudo

Os dados foram obtidos de uma estação fluviométrica e de 5 estações pluviométricas convencionais, situadas na Bacia Hidrográfica do Rio Preto (BHRP), entre os estados de Minas Gerais e Rio de Janeiro, no sudeste do Brasil, importante afluente da Bacia Hidrográfica do Atlântico Sudeste.

As estações são monitoradas pela Agência Nacional das Águas e Saneamento Básico (ANA) e os dados estão disponíveis no portal HidroWeb (<https://www.snirh.gov.br/hidroweb/serieshistoricas>). A série histórica corresponde aos dados de precipitação total mensal e vazão média mensal, entre janeiro de 2000 e dezembro de 2023, totalizando um período de 24 anos. Na Tabela 1, é possível observar a descrição de cada estação, bem como suas localizações.

Tabela 1 - Informações técnicas da estação fluviométrica e das estações pluviométricas.

Estações pluviométricas					
Nome	Código	Município	Altitude (m)	Localização	
				Latitude	Longitude
Pentagna	2243006	Valença-RJ	497,0	-22,1569	-43,7525
Manuel Duarte	2243008	Rio das Flores-RJ	396,0	-22,0858	-43,5567
Fazenda São Gabriel	2243202	Rio Preto-MG	798,0	-22,0117	-43,8750
Santa Isabel do Rio Preto	2244033	Valença-RJ	544,0	-22,2311	-44,0647
Zelinda	2244036	Passa Vinte-MG	550,0	-22,2431	-44,2636
Estação fluviométrica					
Rio Preto	58550001	Rio Preto-MG	426,0	-22,0861	-43,8200

As falhas presentes nas séries históricas de precipitação foram preenchidas, quando necessário, pelo método do Inverso do quadrado da Distância, assim como descrito por Mello e Silva (2013).

Os dados foram organizados no *software Excel* 2016 e, posteriormente, os métodos de ajuste foram aplicados utilizando o *software* estatístico GRETl (Cottrell e Lucchetti, 2017) e R Core Team (2020).

2.2. Modelo SARIMA

Para processos não estacionários, aqueles que apresentam efeitos sazonais e/ou tendências, modelos da classe ARIMA (Autorregressivo-Integrado Médias Móveis) de Box e Jenkins (1976) são mais adequados.

Inicialmente, uma análise descritiva é realizada para um entendimento preliminar das variáveis estudadas. Dado que as séries temporais avaliadas no presente estudo apresentam comportamento periódico sazonal, recorreu-se ao ajuste de modelos SARIMA de ordem $(p, d, q)(P, D, Q)_s$, sendo s o período sazonal do processo, d o número de diferenças regulares e D o número de diferenças sazonais necessárias para eliminar a tendência e a sazonalidade.

Supondo uma sazonalidade de 12 meses, ou seja, $s = 12$, o modelo SARIMA pode ser representado por um polinômio, conforme a Eq. (1).

$$\begin{aligned}
 & (1 - \Phi_1 B^{12} - \dots - \Phi_P B^{12P}) (1 - \phi_1 B - \dots - \phi_P B^p) \\
 & (1 - B)^d (1 - B^{12})^D Y_t = (1 - \Theta_1 B^{12} - \Theta_Q B^{12Q}) \\
 & (1 - \Theta_1 B - \dots - \Theta_q B^q) e_t
 \end{aligned} \quad (1)$$

em que $e_t \sim N(0, \sigma^2)$ é denominado um ruído branco, B é o operador de retardo, $(B_n Y_t = Y_{t-n})$, $(1 - \Phi_1 B^{12} - \dots - \Phi_P B^{12P})$ é o polinômio autorregressivo sazonal (AR) de ordem P , $(1 - \Theta_1 B^{12} - \dots - \Theta_Q B^{12Q})$ é o polinômio sazonal de médias móveis (MA) de ordem Q , $(1 - \phi_1 B - \dots -$

$\phi_p B^p$) e $(1 - \Theta_1 B - \dots - \Theta_q B^q)$ são os polinômios autorregressivos e de médias móveis de ordem p e q , respectivamente (Moretini e Toloi, 2018).

Para encontrar um modelo SARIMA adequado para obter as previsões, recorreu-se à metodologia Box e Jenkins (1976). Na fase de identificação, avaliou-se a presença das componentes sazonalidade e tendência nas séries temporais pelo método dos Mínimos Quadrados Ordinários (MQO) e obteve-se a densidade espectral para verificação de componentes periódicos inerentes destes dados. Ainda, realizou-se análise gráfica dos resultados das funções de autocorrelação (FAC) e autocorrelação parcial (PACF), por meio do correlograma. Caso a presença de alguma das componentes seja evidenciada, faz-se necessário realizar as diferenciações adequadas para se obter séries estacionárias.

Com as séries diferenciadas, os parâmetros de d e/ou D são definidos e inicia-se os procedimentos de identificação das ordens e estimação do modelo. Posteriormente, é necessário avaliar a estrutura residual, de modo que os resíduos resultantes sejam do tipo ruído branco, utilizando o teste de Box & Pierce (Box e Pierce, 1970). Nestas etapas, é importante analisar novamente os FAC e PACF de modo a embasar a especificação das ordens possíveis dos modelos e verificar o comportamento dos resíduos auferidos.

Para seleção do modelo que melhor se ajustou aos dados, adotou-se os critérios de informações de Akaike (AIC) (Akaike, 1974), Hannan e Quinn (HQ) (Hannan e Quinn, 1979) e Schwarz (SW) (Schwarz, 1978). O modelo mais adequado é aquele que apresenta o menor valor de, pelo menos, dois critérios de seleção. Após a avaliação de todos os modelos, as previsões foram obtidas com base no melhor modelo selecionado.

2.3. Avaliação das previsões

Dado o objetivo de obter modelos que viabilizem a obtenção de previsões acuradas, inicialmente, realiza-se a validação dos modelos ajustados aos dados observados. Para isso, utilizou-se três diferentes medidas de erro, a raiz do erro médio quadrático (REMQU), o Percentual bias (PBIAS) e o coeficiente de correlação de Pearson (r), também descrito por Xavier et al. (2016).

A Eq. (2) apresenta a REMQU que avalia a magnitude da diferença entre valores estimados e observados, por meio do cálculo do quadrado do desvio entre os valores observados e estimados. Essa medida varia de zero a valores positivos, sendo que quanto mais próximo de zero, melhor a precisão do modelo (Zhi, 2009; Kannan et al., 2007).

$$REMQU = \sqrt{\frac{\sum_{i=1}^n (obs_i - est_i)^2}{n}} \quad (2)$$

Sendo que obs são os dados observados, est são os dados estimados e n é o número de observações.

O PBIAS calcula o viés, apresentado pela Eq. (3), em que valores próximos de zero indicam uma tendência ideal, $PBIAS > 0$ indica subestimação do modelo e $PBIAS < 0$ indica superestimação (Gupta, Sorooshian e Yapo, 1999). Os módulos dos valores foram classificados da seguinte maneira: $|BIAS| < 10\%$ é considerado muito bom; $10\% < |BIAS| < 15\%$ é considerado bom; $15\% < |BIAS| < 25\%$ é satisfatório, e $|BIAS| > 25\%$, é considerado inadequado (Donigian et al., 1983; Liew et al., 2007).

$$PBIAS = \left[\frac{\sum_{i=1}^n (obs_i - est_i)}{\sum_{i=1}^n obs_i} \right] \cdot 100 \quad (3)$$

A correlação de Pearson indica grau de dependência linear entre os dados observados e estimados, como evidencia-se na Eq. (4), e varia entre -1 e 1, em que os valores negativos indicam dependência inversa, enquanto os valores positivos indicam dependência diretamente proporcional. De acordo com a classificação de Hopkins (2016), as correlações significativas podem ser categorizadas como: $0,0 < r \leq 0,1$ (Muito baixo), $0,1 < r \leq 0,3$ (Baixo), $0,3 < r \leq 0,5$ (Moderado), $0,5 < r \leq 0,7$ (Alto), $0,7 < r \leq 0,9$ (Muito alto) e $0,9 < r \leq 1,0$ (Extremamente alto).

$$r = \frac{\sum_{i=1}^n (obs_i - \underline{obs}) \cdot (est_i - \underline{est})}{\sqrt{\sum_{i=1}^n (obs_i - \underline{obs})^2 \cdot \sum_{i=1}^n (est_i - \underline{est})^2}} \quad (4)$$

Em que obs são os dados observados, $\underline{obs}$ é a média dos dados observados, est são os dados estimados, $\underline{est}$ é a média dos dados estimados e n é o número de observações.

De forma a contribuir com o processo de validação das previsões, foi obtido também o coeficiente de determinação (R^2) que indica o quanto da variação da variável dependente (dados estimados pelo modelo SARIMA) pode ser explicado pela variação da variável independente (dados observados na estação fluviométrica e nas estações pluviométricas), variando de 0 a 100%.

E, por fim, a eficiência dos modelos foi analisada por meio do coeficiente de Nash-Sutcliffe (C_{NS}), segundo a Eq. (5).

$$C_{NS} = 1 - \left[\frac{\sum_{i=1}^n (obs_i - est_i)^2}{\sum_{i=1}^n (obs_i - \underline{obs})^2} \right] \quad (5)$$

Conforme a classificação de Moriasi et al. (2007), valores altos de C_{NS} indicam um melhor ajuste do modelo, sendo: $C_{NS} = 1$, muito bom; $0,54 < C_{NS} < 0,65$, bom; $0,50 < C_{NS} < 0,54$, satisfatório.

Após a obtenção e avaliação dos modelos em termos da acurácia da predição, obteve-se as previsões para os dados da estação fluviométrica e das cinco estações pluviométricas, entre janeiro de 2024 e dezembro de 2030, de

acordo com método apresentado por [Morettin e Tolo \(2018\)](#). [Silva *et al.* \(2006\)](#) demonstraram que previsões climáticas de longo prazo, acima de 9 meses, implicam em benefícios na gestão ambiental, particularmente interessantes no Brasil, que apresenta matriz elétrica baseada principalmente na energia hidráulica.

3. Resultados e Discussão

3.1. Análise descritiva da bacia hidrográfica e das séries temporais

O mapa com a localização de cada estação na BHRP é apresentado na [Fig. 1](#). A área da BHRP abrange aproximadamente 3.411,974 km² e está inserida predominantemente no bioma Mata Atlântica. O clima da região é classificado segundo Köppen como Cwa - tropical de altitude, com inverno seco e verão chuvoso ([Alvares, 2013](#)), com precipitações médias anuais em torno de 1.536 mm.

O trabalho de [Oliveira e Ferreira \(2017a\)](#) demonstrou que a forma do relevo da bacia é o principal fator geográfico que influencia o clima local/regional, atuando como barreira ou direcionador dos sistemas atmosféricos, contribuindo, ou não, com a formação de chuvas orográficas e com a distribuição espacial da precipitação. A re-

gião da nascente, localizada a sudoeste da bacia, com altitudes que podem chegar a 2400 m, apresenta os maiores índices de precipitação, superiores a 1800 mm, enquanto a foz, com altitudes em torno de 600 m, apresenta precipitações que chegam, no máximo, a 1000 mm.

Além da heterogeneidade do relevo, [Oliveira e Ferreira \(2017b\)](#) observaram que os sistemas de Massa Tropical Atlântica, Massa Polar Atlântica, as Linhas de Instabilidade, a Zona de Convergência do Atlântico Sul e os sistemas frontais, influenciaram a distribuição da precipitação da BHRP, no ano de 2006.

Os gráficos das séries temporais de precipitação e vazão, que podem ser observados na [Fig. 2](#), estão evidenciadas a presença das variações mensais e anuais. O período menos chuvoso, para a BHRP, está compreendido entre os meses de abril e setembro, e o período chuvoso está compreendido entre os meses de outubro e fevereiro, com base na precipitação média mensal.

Para todas as séries temporais, a maior densidade espectral (pico) está associada à frequência $f_t = 21$, aproximadamente, indicando um componente sazonal com período de $\frac{1}{f_t} = \frac{1}{21} = 12$ meses. Como os dados analisados correspondem a variáveis hidrológicas/meteorológicas, a presença da sazonalidade era esperada, assim como observado por [Barbosa *et al.* \(2015\)](#).




Figura 1 - Localização da Bacia Hidrográfica do Rio Preto, sudeste do Brasil, das estações pluviométricas e da fluviométrica.




Figura 2 - Gráficos das séries temporais da Bacia Hidrográfica do Rio Preto, precipitação total mensal e vazão mensal, referentes às estações pluviométricas: (A.) Pentagna - 2243006, (B.) Manuel Duarte - 2243008, (C.) Fazenda São Gabriel - 2243202, (D.) Santa Isabel do Rio Preto - 2244033, (E.) Zelinda - 2244036, (F.) estação fluviométrica Rio Preto - 58550001.

Na **Tabela 2**, são demonstrados os valores dos coeficientes obtidos para o teste de tendência dos mínimos quadrados generalizados, juntamente com o p-valor, para os dados de precipitação observados nas estações pluviométricas e para os dados de vazão observados na estação fluviométrica. É possível observar que os dados de todas as estações não apresentaram tendência (p-valor > 0,05).

Tabela 2 - Valores dos coeficientes, juntamente com o p-valor, obtidos para o teste de tendência para as estações pluviométricas e para a estação fluviométrica.

Código das estações	Coefficientes	p-valor
2243006	-0,1575	0,1433
2243008	-0,0279	0,7543
2243202	0,0594	0,6404
2244033	-0,0442	0,6562
2244036	-0,0087	0,9400
58550001	-0,0140	0,6192

Tabela 3 - Modelos SARIMA aplicados aos dados de cada estação, juntamente com os critérios de avaliação Akaike (AIC), Swarzh (SW) e Hannan e Quinn (HQ), sendo os modelos destacados em negrito aqueles que apresentaram os menores valores dos critérios de avaliação.

Código das estações	Modelos	Critérios de avaliação		
		AIC	SW	HQ
2243006	SARIMA(0,0,0) (1,1,0)	3245,754	3252,995	3248,660
	SARIMA(0,0,0) (0,1,1)	3174,310	3181,551	3177,216
	SARIMA(0,0,0) (1,1,1)	3176,091	3186,952	3180,449
	SARIMA(0,0,0) (0,1,0)	3316,948	3324,189	3319,854
2243008	SARIMA(0,0,0) (1,1,0)	3185,344	3192,585	3188,250
	SARIMA(0,0,0) (0,1,1)	3112,078	3119,319	3114,984
	SARIMA(0,0,0) (1,1,1)	3114,048	3124,909	3118,406
	SARIMA(0,0,0) (0,1,0)	3256,381	3260,001	3257,834
2243202	SARIMA(0,0,0) (1,1,0)	3351,653	3358,894	3354,558
	SARIMA(0,0,0) (0,1,1)	3274,107	3281,347	3277,012
	SARIMA(0,0,0) (1,1,1)	3276,081	3286,942	3280,439
	SARIMA(0,0,0) (0,1,0)	3426,222	3433,463	3429,128
2244033	SARIMA(0,0,0) (1,1,0)	3211,158	3218,398	3214,063
	SARIMA(0,0,0) (0,1,1)	3156,484	3163,725	3159,390
	SARIMA(0,0,0) (1,1,1)	3158,113	3168,974	3162,472
	SARIMA(0,0,0) (0,1,0)	3303,479	3310,720	3306,385
2244036	SARIMA(0,0,0) (1,1,0)	3331,387	3338,628	3334,293
	SARIMA(0,0,0) (0,1,1)	3282,362	3289,603	3285,268
	SARIMA(0,0,0) (1,1,1)	3283,559	3294,420	3287,917
	SARIMA(0,0,0) (0,1,0)	3424,939	3432,180	3427,845
58550001	SARIMA(0,0,0) (1,1,0)	2528,435	2535,676	2531,341
	SARIMA(0,0,0) (2,1,0)	2522,463	2533,324	2526,822
	SARIMA(0,0,0) (1,1,1)	2471,164	2472,025	2475,523
	SARIMA(0,0,0) (2,1,1)	2486,561	2472,079	2477,890

3.2. Identificação e seleção dos modelos

Como os dados apresentaram a componente sazonalidade, aplicou-se apenas a primeira diferença sazonal ($D = 1$). Com a série diferenciada sazonalmente, realizou-se o processo de estimação de modelos SARIMA. Os resultados da análise da FAC e FACP apontam um possível comportamento autorregressivo das séries com correlação serial de ordens 1 e 2, demonstrando características de um modelo estacionário, autorregressivo e de médias móveis de ordem 1.

Na **Tabela 3**, é possível observar a especificação dos modelos SARIMA ajustados aos dados de precipitação total mensal e para a vazão mensal, com os respectivos critérios de avaliação. Para os dados de precipitação mensal, o modelo SARIMA (0,0,0)x(0,1,1) foi o que apresentou os menores valores dos critérios de avaliação para as cinco estações pluviométricas, e para os dados de vazão mensal, o modelo SARIMA (1,0,0)x(0,1,1) resultou nos menores valores dos critérios de avaliação.

Santos *et al.* (2021) obtiveram o mesmo modelo (SARIMA (0,0,0)x(0,1,1)), ao ajustar os dados de precipitação média mensal da cidade de Lavras/MG, para o período de janeiro de 2000 a dezembro de 2018. Os autores concluíram que o modelo ajustado alcançou um resultado excelente, já que os intervalos de confiança de 95% englobam todos os doze valores reais da precipitação média mensal em Lavras/MG no ano de 2019, mesmo frente aos imprevistos e incertezas relacionadas a fatores climáticos. Essa precisão é particularmente significativa, pois demonstra a robustez do modelo em prever com precisão os padrões de precipitação, mesmo quando confrontado com a variabilidade e complexidade dos fenômenos climáticos.

As estimativas dos parâmetros e os respectivos erros padrão dos modelos obtidos são apresentados na Tabela 4. Os modelos estimados foram validados por meio do diagnóstico de correlação serial nos resíduos padronizados pela estatística Q(20), obtida com o teste de Box & Pierce.

Na Fig. 3, ainda podem ser observadas a FAC e FACP dos resíduos dos modelos selecionados pelos critérios (SARIMA (0,0,0)x(0,1,1)) referentes aos dados de precipitação, e para o modelo SARIMA (1,0,0)x(0,1,1), referente aos dados de vazão. Os resultados indicam que os ajustes foram significativos, ou seja, os resíduos não são correlacionados e representam um ruído branco.

Logo, os resultados indicam que os quatro modelos testados, tanto para as estações pluviométricas como para a estação fluviométrica, apresentaram ajustes significativos, com exceção do modelo SARIMA(1,0,1)x(0,1,1) para a estação pluviométrica 2243008, ou seja, os resíduos não são correlacionados e representam um ruído branco.

3.3. Análise das previsões

A fim de avaliar a diferença dos valores observados em relação aos preditos pelo modelo SARIMA (0,0,0)x(0,1,1), selecionado para as estações pluviométricas, e SARIMA (1,0,0)x(0,1,1), selecionado para a estação fluviométrica, foram utilizados os dados de janeiro de 2000 a dezembro de 2023.

Os resultados obtidos nas estimativas das medidas de erro REMQ e PBIAS, bem como o coeficiente de cor-

relação de Pearson (r) e o coeficiente de determinação (R^2) podem ser observados na Tabela 5.

Com base na análise da medida PBIAS, é possível afirmar que os dados de precipitação e de vazão obtidos pelo modelo SARIMA foram subestimados, com exceção da estação pluviométrica 2243006, que apresentou superestimativa dos dados, indicada pelo sinal negativo. Considerando a classificação de Liew *et al.* (2007), todos os modelos gerados podem ser classificados como muito bons, com $|BIAS| < 10\%$.

A estação pluviométrica 2244036 resultou no maior valor da REMQ (83,8), assim como o menor valor para o r (0,79) e para o R^2 (61,9%), indicando uma menor precisão para a estimativa dos dados dessa estação em relação à estimativa dos dados das demais estações. A estação pluviométrica 2243202 resultou nas melhores estimativas de erro para o r (0,83) e R^2 (69,2%), sendo a correlação considerada como muito alta, segundo a classificação de Hopkins (2016).

Embora as estações pluviométricas tenham convergido para um mesmo modelo SARIMA, houve diferenças nas estimativas de erro entre os valores observados e estimados. A dificuldade na estimativa de um modelo de previsões de chuva, para a BHRP, pode estar relacionada à heterogeneidade do relevo e aos diferentes sistemas atmosféricos que atuam na região, conforme relatado por Oliveira e Ferreira (2017a).

Em relação ao C_{NS} todos os modelos foram superiores a 0,80 indicando um bom ajuste deles, principalmente para a estimativa dos dados de vazão, que resultou em um C_{NS} de 0,90. Nesse sentido, conforme sugerido por Zappa (2002), modelos ajustados com valores de C_{NS} superiores a 0,50 podem ser utilizados para realizar previsão.

A estimativa dos dados de vazão para a estação 58550001 apresentou bons resultados considerando as estimativas de erro, com valor de r classificado como muito alto, demonstrando que o modelo selecionado para realizar a predição da vazão é adequado.

Observa-se um bom ajuste dos modelos, com base nas estimativas de erro, embora eles não sejam totalmente precisos. Tal situação é explicada pelo fato de que os processos aleatórios são controlados pela lei da probabilidade, pelo que estabelece um modelo de probabilidade pertencente ao domínio do tempo previamente estabelecido (Reisen *et al.*, 2008), indicando que eventos extremos podem não ser 100% previstos, pois estão associados às leis de probabilidade declaradas em modelos de previsão (Bleidorn *et al.*, 2019).

3.4. Previsões de longo prazo

Visando o planejamento e a operação dos recursos hídricos, previsões foram realizadas para o período de janeiro de 2024 a dezembro de 2030 para os dados da estação fluviométrica e para as cinco estações pluviométricas. Os resultados são observados na Fig. 4, em que os dados

Tabela 4 - Estimativas dos parâmetros, juntamente com o erro padrão, dos modelos obtidos para a série temporal de cada estação.

Código das estações	Parâmetro	Estimativa	Erro padrão	Q(20)
2243006	Θ	-0,8630	0,0407	0,80
2243008	Θ	-0,9999	0,0465	0,79
2243202	Θ	-1,0000	0,1127	0,37
2244033	Θ	-1,0000	0,0565	0,91
2244036	Θ	-1,0000	0,0865	0,35
58550001	ϕ	0,1236	0,0616	-
	Θ	-1,000	0,0417	0,12

observados no período de janeiro de 2000 a dezembro de 2023, estão representados pela linha cinza, os dados estimados estão representados pela linha vermelha e as previsões representadas pela linha azul.

Valipour (2015) avaliou a capacidade dos modelos de média móvel integrada autorregressiva (ARIMA) e SARIMA para realizar previsões de longo termo do escoamento nos Estados Unidos (EUA). Os modelos foram




Figura 3 - Gráficos das Funções de Autocorrelação (FAC) dos resíduos do modelo SARIMA que apresentaram o melhor ajuste para os dados das cinco estações pluviométricas e da estação fluviométrica da Bacia Hidrográfica do Rio Preto: (A.) Pentagna - 2243006, (B.) Manuel Duarte - 2243008, (C.) Fazenda São Gabriel - 2243202, (D.) Santa Isabel do Rio Preto - 2244033, (E.) Zelinda - 2244036, e para a (F) estação fluviométrica Rio Preto - 58550001.

Tabela 5 - Valores das diferentes estimativas de erro, entre os valores observados e estimados pelo modelo SARIMA, para a estação fluviométrica e para as estações pluviométricas.

Código das estações	REMQ	PBIAS	r	R^2 (%)	C_{NC}
2243006	71,6	-7,2	0,82	67,3	0,83
2243008	61,5	2,8	0,81	65,0	0,83
2243202	82,5	4,1	0,83	69,2	0,86
2244033	66,7	0,1	0,81	65,4	0,84
2244036	83,8	5,9	0,79	61,9	0,82
58550001	19,3	1,5	0,81	64,9	0,90

ajustados aos dados de escoamento médios anuais para o período de 1901 a 2000, posteriormente realizado a previsão para o período de 2001 a 2011 e por fim verificada a acurácia das previsões. O autor observou que o modelo SARIMA com termo periódico igual a 20, R^2 igual a 0,91 e erro de viés médio de 1,29 demonstrou ser o melhor modelo.

Esses resultados podem auxiliar na gestão da disponibilidade hídrica em períodos de estresse hídrico, conforme observado por Duarte *et al.* (2019), cujas análises, modelagens e previsões com base nas séries temporais de vazões mensais da bacia hidrográfica do rio Manuel Alves da Natividade utilizando o modelo SARIMA(1,0,1)x(1,1,4)₁₂, apresentaram coeficiente de Nash-Sutcliffe de 0,61 e 0,81 para as etapas de calibração e validação, respectivamente, valores esses classificados como “bom”, segundo a classificação para modelos hidrológicos.

Silva (2005) destaca que os modelos estocásticos, ao incorporarem correlações temporais e sazonais, são eficazes para prever o comportamento do escoamento em bacias hidrográficas onde o fluxo de água ocorre de maneira lenta, o armazenamento subterrâneo predomina e a declividade do terreno é baixa. Entretanto, a BHRP, conforme discutido anteriormente, apresenta o relevo bastante heterogêneo, principalmente na região da nascente, onde as elevações do terreno estão em torno dos 2400 m, atuando como barreira orográfica e influenciando na dis-




Figura 4 - Gráfico das previsões dos modelos, para cada estação, para o período de janeiro de 2024 a dezembro de 2030: (A.) Pentagna - 2243006, (B.) Manuel Duarte - 2243008, (C.) Fazenda São Gabriel - 2243202, (D.) Santa Isabel do Rio Preto - 2244033, (E.) Zelinda - 2244036, e para a (F.) estação fluviométrica Rio Preto - 58550001.

tribuição da chuva, indicando que a metodologia utilizada demonstra bons resultados para áreas com variabilidade climática e topográfica.

4. Conclusão

O presente trabalho realizou o ajuste de um modelo estocástico do tipo SARIMA para cinco séries de precipitação total mensal e para uma série de vazão mensal, pertencentes à Bacia Hidrográfica do Rio Preto, no sudeste do Brasil, após explicitar a importância do campo de gerenciamento dos recursos hídricos e ambientais.

Com base nos critérios de seleção aplicados, as séries de precipitação convergiram para um mesmo modelo, sendo o modelo SARIMA (0,0,0)x(0,1,1) o mais adequado para descrevê-las, e para a série de vazão, o modelo mais adequado foi o SARIMA (1,0,0)x(0,1,1). Considerando as análises das predições, todos os modelos apresentaram ajustes satisfatórios, com destaque para o modelo SARIMA ajustado aos dados de precipitação que apresentaram coeficiente de Nash-Sutcliffe superiores a 0,82 e 0,90 para o modelo ajustado aos dados de vazão.

Os modelos do tipo SARIMA demonstraram boa capacidade em modelar e prever os dados de precipitação e vazão de uma bacia hidrográfica com relevo e sistemas atmosféricos heterogêneos. Eles foram capazes de incorporar as características, como a sazonalidade e a correlação serial, e demonstraram bons ajustes aos dados, qualificando-os para a realização de previsões de longo termo, que foram feitas em um horizonte de 84 meses.

Como proposta para estudos futuros para a Bacia Hidrográfica do Rio Preto, é importante considerar a inclusão de variáveis explicativas, como evapotranspiração e temperatura, a fim de aprimorar significativamente esses modelos, contribuindo com a gestão de enchentes e inundações, uma vez que os resultados obtidos com os modelos SARIMA podem ser utilizados como parâmetros para medir a disponibilidade hídrica para a região. Nesse sentido, recomenda-se a extensão dos modelos SARIMA que incluem covariáveis, conhecidos como modelos SARI-MAX.

Referências

- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716-723, 1974. [doi](#)
- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.D.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- BARBOSA, E.C.; SÁFADI, T.; NASCIMENTO, M.; NASCIMENTO, A.C.C.; SILVA, C.H.O.; et al.. Metodologia Box & Jenkins para previsão de temperatura média mensal da cidade de Bauru (SP). **Revista Brasileira de Biometria**, v. 33, n. 1, p. 104-117, 2015.
- BLEIDORN, M.T.; DE PAULA PINTO, W.; BRAUM, E.S.; LIMA, G.B.; MONTEBELLER, C.A. Modelagem e previsão de vazões médias mensais do rio Jucu, ES, utilizando o modelo SARIMA. **Irriga**, v. 24, n. 2, p. 320-335, 2019. [doi](#)
- BOX, G.P.; PIERCE, D.A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509-1526, 1970. [doi](#)
- BOX, G.P.; JENKINS, G.M. **Time Series Analysis, Forecasting and Control**. San Francisco: Holden-Day, 1976.
- CAIXETA, L.T.; MENEZES FILHO, F.C.M.; FONSECA, V.L.A. 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, 2021. [doi](#)
- CINTRA, R.A.; MELO, M.I.P.; BUENO FILHO, J.S.S. Modelos de séries temporais para a previsão da temperatura média mensal de Lavras, MG. **Sigmae**, v. 8, n. 2, p. 596-605, 2019.
- COTTRELL, A.; LUCCHETTI, R. **Gretl User's Guide: GNU Regression, Econometrics and Time-Series Library**. Gretl, 2016. Software and documentation. Available at <https://gretl.sourceforge.net>.
- DONIGIAN, A.S.; IMHOFF, J.C.; BICKNELL, B.R. Predicting water quality resulting from agricultural nonpoint source pollution via simulation-HSPF. In: **Agricultural Management and Water Quality**. Ames: Iowa State University Press, p. 200-249, 1983.
- DOS SANTOS, T.R. Uma comparação dos modelos SARIMA e estruturais para a previsão da incidência de dengue em Belo Horizonte, Minas Gerais. **Revista Brasileira de Biometria**, v. 35, n. 1, p. 98-114, 2017.
- DUARTE, V.B.R.; SILVA, F.D.C.S.; SOUZA, I.V.; SILVA, M.V.C.; DE ALMEIDA SOUSA, H.G.; 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. [doi](#)
- ESPINOSA, M.M.; PRADO, S.M.; GHELLERE, M. Uso do modelo SARIMA na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso. **Ciência e Natura**, v. 32, n. 2, p. 7-21, 2010.
- FERREIRA, C.C.M. **Tipos de Tempo de Categorias Climáticas na Bacia do Rio Paraíba - MG**. Tese de Doutorado em Geografia, Universidade de São Paulo, São Paulo, 2002.
- FERREIRA, G.W.; REBOITA, M.S. A new look into the South America precipitation regimes: Observation and forecast. **Atmosphere**, v. 13, n. 6, p. 873, 2022. [doi](#)
- GUPTA, H.V.; SOROOSHIAN, S.; YAPO, P.O. Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. **Journal of Hydrologic Engineering**, v. 4, n. 2, p. 135-143, 1999. [doi](#)
- HANNAN, E.J.; QUINN, B.G. The determination of the order of an autoregression. **Journal of the Royal Statistical Society**, v. 41, n. 2, p. 190-195, 1979. [doi](#)
- HOPKINS, W.G. **A New View of Statistics**. Middles Brough: Internet Society for Sport Science. 2016. Disponível em <http://www.sportsci.org/resource/stats>, acesso em 12 de nov. 2023.

- KANNAN, N.; WHITE, S.M.; WORRALL, F.; WHELAN, M.J. Hydrological modelling of a small catchment using SWAT-2000 - Ensuring correct flow partitioning for contaminant modeling. *Journal of Hydrology*, v. 3, n. 34, p. 64-72. 2007. [doi](#)
- LIEW, M.W.; VEITH, T.L.; BOSCH, D.D.; ARNOLD, J.G. Suitability of SWAT for the conservation effects assessment project: A comparison on USDA ARS watersheds. *Journal of Hydrological Research*, v. 12, p. 173-189, 2007. [doi](#)
- MEDEIROS, E.S.; BICALHO, C.C.; SÁFADI, T.; DE LIMA, K.P. Modelo SARIMAX aplicado aos casos de notificações de dengue em Recife, Pe. *Matemática e Estatística em Foco*, v. 6, n. 1, p. 01-11, 2018.
- MELLO, C.R.; SILVA, A.M. *Hidrologia: Princípios e Aplicações em Sistemas Agrícolas*. Lavras: UFLA, 455 p., 2013.
- MENEZES FILHO, F.C.M. Modelagem e previsão de temperaturas médias mensais do Rio Paranaíba/MG utilizando modelos de séries temporais. *Revista Ibero Americana de Ciências Ambientais*, v. 11, n. 6, p. 251-261, 2020. [doi](#)
- MORAIS, P.L.L.; CASTANHA, P.M.S.; NASCIMENTO, G.I.L.A.; MONTARROYOS, U.R. Análise temporal da dengue associada a fatores climáticos em Garanhuns, Pernambuco, Brasil, de 2010 a 2019. *Research, Society and Development*, v. 9, n. 12, e22891211138, 2020. [doi](#)
- MORETTIN, P.A.; TOLOI, C.M.C. *Análise de Séries Temporais: Modelos Lineares Univariados*. São Paulo: Editora Blucher, 2018.
- MORIASI, D.N.; ARNOLD, J.G.; LIEW, M.W.V.; BINGER, R.L.; HARMEL, R.D.; *et al.* Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, v. 50, n. 3, p. 885-900, 2007. [doi](#)
- OLIVEIRA, D.E. *Participação dos Sistemas Atmosféricos na Gênese e Ritmo das Chuvas na Bacia Hidrográfica do Rio Preto, MG/RJ - Anos de 2006, 2007, 2008*. Dissertação de Mestrado em Geografia, UFJF, Juiz de Fora, 151 p., 2016.
- OLIVEIRA, D.E.; AMARAL, C.M.; GIAROLA, I.B.S.; FERREIRA, C.D.C.M. Variabilidade climática e as chuvas de janeiro de 2007: Uma análise episódica na bacia hidrográfica do Rio Preto, Sudeste do Brasil. *Revista da ANPEGE*, v. 18, n. 37, p. 106-136, 2022. [doi](#)
- OLIVEIRA, D.E.; FERREIRA, C.C.M. Aspectos climáticos da bacia hidrográfica do rio Preto MG/RJ, Brasil, influência dos fatores geográficos na formação desse clima regional. *GOT: Revista de Geografia e Ordenamento do Território*, n. 11, p. 283, 2017a. [doi](#)
- OLIVEIRA, D.E.; FERREIRA, C.C.M. Gênese e ritmo da pluviosidade na bacia do rio preto MG/RJ: proposta metodológica para a representação cartográfica. *Revista Brasileira de Climatologia*, v. 13, n. 21, p. 38-58, 2017b. [doi](#)
- OLSZEWSKI, N.; FERNANDES FILHO, E.I.; COSTA, L.M.D.; SCHAEFER, C.E.G.R.; SOUZA, E.D.; *et al.* morphology and hydrological aspects of black river basin, division of state of rio de janeiro and minas gerais. *Revista Árvore*, v. 35, p. 485-492, 2011.
- PEREIRA, A.; COSTA, A.D.S.; OLIVEIRA, V.D.; BORGES, P.D.F.; ISMAEL FILHO, A. Análise do comportamento das médias anuais de precipitação pluvial e temperatura da cidade de Areia, Paraíba. *Gaia Scientia*, v. 9, n. 1, p. 67-73, 2015.
- R Core Team (2020). *R: A Language and Environment for Statistical Computing*. Vienna: R Foundation for Statistical Computing, Available in <https://www.R-project.org>.
- REISEN, V.A.; MOLINARES, F.A.F.; TEIXEIRA, E.C. Modelagem de séries temporais sazonais na presença de outliers: estudo de caso da vazão máxima mensal do rio Jucu, ES, Brasil. *Revista Brasileira de Recursos Hídricos*, v. 13, n. 2, p. 45-53, 2008.
- SÁFADI, T. Uso de séries temporais na análise de vazão de água na represa de Furnas. *Ciência e Agrotecnologia*, v. 28, n. 1, p. 142-148, 2004.
- SANTOS, P.G.P.; OLIVEIRA, T.F. Modelagem e previsão de vazão afluente média mensal no rio Tocantins, usina hidrelétrica Tucuruí-Pará, Amazônia, Brasil. *Biota Amazônia*, v. 6, n. 2, p. 9-16, 2016. [doi](#)
- SANTOS, P.H.A.B.; DOS SANTOS DELFINO, O.A.; DOS SANTOS, R.V.R.; DO NASCIMENTO, M. Ajuste de um modelo de séries temporais para prever a precipitação pluviométrica. *Research, Society and Development*, v. 10, n. 6, e41810615643, 2021. [doi](#)
- SCHWARZ, G.E. Estimating the dimension of a model. *Annals of Statistics*, v. 6, n. 2, p. 461-464, 1978.
- SILVA, B.C.; TUCCI, C.E.M.; COLLISCHONN, W. Previsão de vazão com modelos hidroclimáticos. *Revista Brasileira de Recursos Hídricos*, v. 11, n. 3, p. 15-29, 2006.
- TADESSE, K.B.; DINKA, M.O. Application of SARIMA model to forecasting monthly flows in Waterval River, South Africa. *Journal of Water and Land Development*, v. 35, n. 1, p. 229, 2017. [doi](#)
- TIBULO, C.; ZANINI, R.R.; TIBULO, V.C. Comparação do desempenho dos modelos estatísticos aplicado a séries temporais de umidade relativa do ar. *Revista Thema*, v. 15, n. 3, p. 808-821, 2018. [doi](#)
- VALIPOUR, M. Long term runoff study using SARIMA and ARIMA models in the United States. *Meteorological Applications*, v. 22, n. 3, p. 592-598, 2015. [doi](#)
- XAVIER, A.C.; KING, C.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980-2013). *International Journal of Climatology*, v. 36, n. 6, p. 2644-2659, 2016. [doi](#)
- ZAPPA, M. *Multiple-Response Verification of a Distributed Hydrological Model at Different Spatial Scales*. Tese de Pós-Doutorado, Swiss Federal Institute of Technology, Switzerland, 2002.
- ZHI, L.; LIU, W.Z.; ZHANG, X.C.; ZHENG, F.L. Impacts of land use change and climate variability on hydrology in an agricultural catchment on the Loess Plateau of China. *Journal of Hydrology*, v. 377, n. 1-2, p. 35-42, 2009. [doi](#)



License information: This is an open-access article distributed under the terms of the Creative Commons Attribution License (type CC-BY), which permits unrestricted use, distribution and reproduction in any medium, provided the original article is properly cited.